



**Maisterintutkielma maantieteessä / Examensarbete i geografi /  
Master's thesis in Geography**

**Geoinformatiikan maisteriohjelma**

Aapasuon ja Keidassuon mikrotopografisten muotojen tunnistus kaukokartoituksella ja  
objektiperusteisella kuvankäsittelyllä Simoskanaavalla

Jarmo Rauhala

2020

Ohjaajat:

Petri Pellikka  
Maarit Middleton

Maantieteen maisteriohjelma / Magisterprogram i geografi /  
Master's Programme in Geography

Matemaattis-luonnontieteellinen tiedekunta / Matematisk-naturvetenskapliga fakulteten /  
Faculty of Science



Tiedekunta – Fakultet – Faculty		Osasto – Institution – Department	
Faculty of Science		Department of Geosciences and Geography	
Tekijä – Författare – Author			
Jarmo Rauhallä			
Tutkielman otsikko – Avhandlings titel – Title of thesis			
Aapasuon ja Keidassuon mikrotopografisten muotojen tunnistus kaukokartoituksella ja objektiperusteisella kuvankäsittelyllä Simoskanaavalla			
Koulutusohjelma ja opintosuunta – Utbildningsprogram och studieinriktning – Programme and study track Maantieteen maiseteriohjelma, geoinformatiikka Master's programme in geography, Physical geography/Human geography/Geoinformatics			
Tutkielman taso – Avhandlings nivå – Level of the thesis	Aika – Datum – Date	Sivumäärä – Sidoantal – Number of pages	
Master's thesis, 40 credits	December 2020	40 + 17 appendixes	
Tiivistelmä – Referat – Abstract			
<p>Ilmaston vaikuttavien tekijöiden ja niistä aiheutuvien kemiallisten ja fysikaalisten prosessien ymmärtäminen auttaa kehittämään parempia ilmastomalleja. Tätä varten tarvitaan pitkän ajan mittauksia hiilen vaihdosta maan ja ilmakehän välillä sekä tietoa eri soiden ravinteisuusluokkien ja niiden mikrotopografisten muotojen spatiaalisesta jakaantumisesta, jotta ilmaston muutoksen vaikutuksia erilaisilla ajallisilla ja spatiaalisilla skaaloilla ymmärrettäisiin paremmin.</p> <p>Pro-gradu tutkimukseni keskittyy kaukokartoituksen, kuvankäsittelyn ja ohjatun luokittelun keinoin erottamaan mätäspinnat, välipinnat ja märkäpinnat Pohjanmaan-Kainuun aapasuovyöhykkeeseen kuuluvalla Simoskanaavan suolla. Aineistona käytettiin korkean resoluution optista WorldView-2 satelliittikuvaa ja Maanmittauslaitoksen laserkeilausaineistosta luotua 2 metrin pikselikokoon interpoloitua korkeusmallia. Ohjatussa luokittelussa käytettiin objektiperusteista luokittelua ja tukivektorikoneita. Objektiperusteinen luokittelu soveltuu kohinaa sisältävälle aineistoille kuten mahdollisesti suoalueilta otetut kaukokartoitusaineistot ovat.</p> <p>Luokittelu onnistui hyvin Simoskanaavan keidassuoalueella: kuuden mikrotopografisen muotojen luokittelutarkkuudeksi laskettiin 84,1 % (kappa 0.672). Aapasoilla kokonaisluokittelun tarkkuus oli viidelle luokalle (allikoita ei ollut) hieman heikompi (76,3 %, kappa 0.650), mikä johtui välipinta-märkäpintatasojen ja väli-märkäpintatasojen sekoittumisesta. Objektiperustainen luokittelu soveltuu hyvin tiettyjen suon mikropintojen luokitteluun. Tutkimuksessani pystyttiin erottamaan hyvin aapasuon jänteet ja märkäpinnat, keidassuon kermat ja märkäpinnat sekä väli-mätäspinnat toisistaan. Jatkotutkimuksessa voidaan käyttää tarkempaa laserkeilausaineistoa sekä korkearesoluutioista satelliittikuvaa, joiden avulla suo luokitellaan suotyyppeihin, joille lasketaan päästökertoimia hyväksi käyttäen suon hiilitaseet</p>			
Avainsanat – Nyckelord – Keywords			
kaukokartoitus, keidassuo, aapasuo, mikrotopografia, objektiperustainen luokittelu, WorldView-2, tukivektroikone			
Säilytyspaikka – Förvaringställe – Where deposited			
University of Helsinki electronic theses library E-thesis/HELDA			
Muita tietoja – Övriga uppgifter – Additional information			



Tiedekunta – Fakultet – Faculty		Osasto – Institution – Department	
Faculty of Science		Department of Geosciences and Geography	
Tekijä – Författare – Author			
Jarmo Rauhallä			
Tutkielman otsikko – Avhandlingens titel – Title of thesis			
Aapasuon ja Keidassuon mikrotopografisten muotojen tunnistus kaukokartoituksella ja objektiperusteisella kuvankäsittelyllä Simoskanaavalla			
Koulutusohjelma ja opintosuunta – Utbildningsprogram och studieinriktning – Programme and study track Maantieteen maiseteriohjelma, geoinformatiikka Master's programme in geography, Physical geography/Human geography/Geoinformatics			
Tutkielman taso – Avhandlingens nivå – Level of the thesis	Aika – Datum – Date	Sivumäärä – Sidoantal – Number of pages	
Master's thesis, 40 credits	December 2020	40 + 17 appendixes	
Tiivistelmä – Referat – Abstract			
<p>Understanding the factors that affect the climate and the resulting chemical and physical processes will help to develop better climate models. This requires long-term measurements of carbon exchange between the earth and the atmosphere, as well as information on the spatial distribution of different bog nutrient classes and their microtopographic forms, in order to better understand the effects of climate change on different temporal and spatial scales.</p> <p>My master's thesis focuses on the separation of rotting surfaces, interfaces and wet surfaces in the Simoskanaapa bog, which belongs to the Ostrobothnia-Kainuu bog zone, by means of remote sensing, image processing and guided classification. The material used was a high-resolution Optical satellite image of WorldView-2 and an altitude model interpolated to a pixel size of 2 meters, created from the laser scanning data of the National Land Survey of Finland. Object-based classification and support vector machines were used in the guided classification. Object-based classification is suitable for data containing noise, such as remote sensing data taken from bogs. The classification was successful in the ombrotrophic raised bog area of the Simoskanaava bog: the classification accuracy of the six microtopographic forms was calculated to be 84.1% (kappa 0.672). At the aapa-mire, the accuracy of the overall classification was slightly lower for the five classes (76.3%, kappa 0.650), due to the mixing of the interface wet surface levels and intermediate-wet surface levels.</p> <p>Object-based classification is well suited for the classification of certain bog microsites. In my study, it was possible to distinguish well the ridges and wet surfaces of the aapa mire, ridges and wet surfaces of the ombrotrophic raised bog area, and the intermediate sphagnum sp. surfaces. Further research can use more accurate laser scanning data as well as high-resolution satellite imagery to classify the bog into bog types for which emission factors are calculated using the bog's carbon balances.</p>			
Avainsanat – Nyckelord – Keywords			
Remote Sensing, ombrotrophic raised bog area, aapa-mire, microtopography, object-based classification, WorldView-2, SVM			
Säilytyspaikka – Förvaringställe – Where deposited			
University of Helsinki electronic theses library E-thesis/HELDA			
Muita tietoja – Övriga uppgifter – Additional information			

# Contents

1 JOHDANTO .....	1
2. TAUSTA .....	2
2.1 Suomen suot .....	2
2.2 Ilmastomuutos ja hiilen sitoutuminen soihin .....	3
2.3 Kaukokartoitusmenetelmät .....	7
2.4. Soiden kaukokartoitus .....	9
2.5 Kaukokartoitusaineistojen kuvankäsittely ja soiden luokittelu .....	11
3. TUTKIMUSALUE .....	12
3.1 Tutkimusalue .....	12
4. AINEISTO JA KÄSITTELY .....	14
4.1 Käytettävät kaukokartoitusaineistot .....	14
4.1.1 WorldView-2 .....	14
4.1.2 Laserkeilausaineisto ja korkeusmalli .....	16
4.2.3 Vääräväri-ilmakuva-aineisto .....	16
4.3 Kuvankäsittely ja luokittelumenetelmät .....	17
4.3.1 TDR .....	17
4.3.2 Topografinen positio-indeksi .....	18
4.3.3 Objektiperusteinen kuvan segmentointi .....	19
4.3.4 Mikrotopografisten luokkien valinta .....	21
4.3.5 Objektien luokittelu tukivektoreilla .....	23
4.3.6 Luokittelun luotettavuuden laskenta .....	25
Testialueet .....	26
5. TULOKSET .....	27
5.1 Keidassuon luokittelu .....	27
5.2 Aapasuon luokittelu .....	29
6. TULOSTEN TARKASTELU .....	32
6.1 Luokittelun luotettavuus .....	32
6.2 Merkitys hiilivarastona .....	36
6.3 Hiilitase .....	38
6.4 Virhelähteet .....	39
6.5 Jatkotutkimukset .....	39
7. YHTEENVETO .....	40

8. KIITOKSET .....	40
9. LÄHTEET.....	41
10.LIITTEET .....	54

## Lyhenteet/List of abbreviations

AVHRR	Advanced very high resolution radiometer
C	Carbon
$CO_2$	Carbon dioxide
CORINE	Coordination of information on the environment
GPP	Gross primary production
GPS	Global Position System
IMU	Inertial Measure Unit
IPCC	International Panel of Climate Change
LiDAR	Light Detection and Rangeing
LORCA	Long-term apparent rate of carbon accumulation
LULUCF	Land and Use, Land Use Change and Forest
NDVI	Normalized Difference Vegetation Index
$NH_4$	Methane
NEE	Net ecosystem exchange
$N_2O$	Nitrous oxide
NIR	Near infrared
NPP	Net primary production
PPM	Parts per million; 10 000 ppm = 1 %
RERCA	Recent apparent rate of carbon accumulation
SfM	Structure from motion
SVM	Support vector machine
USGS	United States Geological Survey

# 1 JOHDANTO

Hiilen varastoina toimivat valtameret ja niiden pohjasedimentit, biosfääri, maaperä sekä makeat vedet (IPCC 2013). Maanpäällinen hiili käsittää kaksi kolmasosaa kaikesta maapallon orgaanisesta hiilestä (Post et al. 1982), josta soihin on varastoituneena maailmanlaajuisesti huomattavia määriä hiiltä. Esimerkiksi boreaalisiin ja subarktisiin soihin arvioidaan sitoutuneen kolmannes kaikesta maapallon hiilestä (Gorham 1991; Post et al. 1982). Soiden hiilestä 98,5% on sitoutunut turpeeseen ja noin 1,5% suokasvillisuuteen (Gorham 1991). Soiden merkitys ilmakehän kasvihuonekaasujen määrään on huomattava. (Yu 2012)

Hiilen kiertoaika vaihtelee muutamasta vuodesta yli 10000 vuoteen tai pidempään aikaan. Luonnollinen hiilenkierto on melko pientä ollen alle  $0,3 \text{ Pg C yr}^{-1}$ . Hiiltä vapautuu vulkaanisessa toiminnassa, kemiallisessa rapautumisessa, ihmisen vaikutuksesta maankäyttöön ja jokien kuljettamista ( $0,3 \text{ Pg C yr}^{-1}$ ) maa-aineksista. Maanpäällisissä ekosysteemeissä hiili sitoutuu biomassaan ja kuolleisiin kasvin osiin. Hiili poistuu ilmakehästä fotosynteesissä ja varastoituu kasvin eläviin osiin. Kasvien kuoltua hajotustoiminta vapauttaa hiiltä puolestaan takaisin ilmakehään. (IPCC 2013). Suomessa maankäytön vaikutuksia hiilen vapautumisessa ovat mm. turvetuotanto sekä soiden ojitukset metsätalouskäyttöön. (Turunen ja Valpola 2020).

Yhdistyneiden kansakuntien ilmastopuitesopimusta täydentää ns. Kioton pöytäkirja. Siinä asetetaan sitovat velvoitteet kehittyneiden maiden kasvihuonekaasupäästöille.

Vähennysvelvoitteissa huomioidaan myös hiilinielujen vaikutukset. Ensimmäisen velvoitekauden tavoitteena oli pitää kasvihuonepäästöt vuoden 1990 tasolla. Toisella velvoitekaudella on tavoitteena vähentää päästöjä viidenneksellä vuoden 1990 tasosta. (Ympäristöministeriö 2020) Tilastokeskus raportoi kasvihuonetaseensa vuosittain YK:n ilmastopuitemuutokselle ja Euroopan komissiolle. (Tilastokeskus 2020a) Maankäytön piirissä olevat turvemaista metsäojitetut suot ja turvetuotantoalueet kuuluvat LULUCF (Land and Use, Land Use Change and Forest) -kasvihuonekaasuinventaarion piiriin. (Maa- ja metsätalousministeriö 2020)

Ympäristöministeriö 2020) Kioton sopimuksen mukaisesti Turunen et al. (2002) arvioivat hiilen pitkäaikaistalveutusta (LORCA) suotyyypeittäin luonnontilaisilla soilla, eli ojitamattomista soista. Kertymä laskettiin jakamalla turvekerroksen hiilimäärä sen iällä. (Turunen et al. (2002)

Pro-gradu tutkimukseni ensisijainen tarkoitus on kaukokartoitusaineistojen ja -menetelmien keinoin erottaa mätäspinnat, välipinnat ja märkäpinnat Pohjanmaan-Kainuun aapasuovyöhykkeeseen kuuluvalla Simoskanaavan suolla. Toisena tavoitteena on tarkastella objektiperusteisen luokittelu- ja tunnistustavan sopivuutta jänteille ja vesipinnoille korkean resoluution spatiaalisista aineistoista. Tutkimuksessa käytetään objektiperusteista kuvankäsittelymenetelmiä laserkeilausaineistosta luotuun 2 m korkeusmalliin ja korkean resoluution WorldView-2- satelliittiaineistoon. Jänteiden ja vesipintojen tunnistus on tärkeää, koska kasvien yhteyttäminen mätäs-, väli- ja rimpipinnoilla vaihtelee vuodenaikojen mukaan vaihtelevan pohjavedenpinnan kanssa. Samoin kuolleiden kasvien lahoaminen vaihtelee vuodenaikojen mukaan. (Alm et al. 1997)

## 2. TAUSTA

### 2.1 Suomen suot

Soiden määritelmä ja luokittelu vaihtelee maittain (International Peatland Society 2020). Suomessa suoksi luokitellaan turvetta tuottava kasviyhdyskunta, jossa on vähintään 75% suokasvillisuutta orgaanisen kerroksen paksuus ollessa yli 30 cm (Laine ja Vasander 2008). Geologisen määritelmän mukaan suoksi lasketaan alueet, joilla turvetta on yli 30 cm ja suon pinta-ala on yli 20 hehtaaria (Virtanen et al 2003). Turve määritellään Suomessa maalajiksi, mikä koostuu epätäydellisesti hajonneista kasvin osista ja on kerrostunut syntypaikalleen. Turpeen orgaanisen aineen osuus on vähintään 75% kuivapainosta. (Laine ja Vasander 2008)

Suot voidaan jakaa suotyyppien samankaltaisuuden ja topografisen sijoittumisen suhteen suoyhdistelmätyyppeihin. Ne ilmentävät kasvialueensa ilmastollista suokasvillisuutta. Suomen suot jakautuvat seitsemään suurempaan suoyhdistymäalueeseen: 1) saaristomeren konsentriset keitaat, 2) rannikko-Suomen kermikeitaat, 3) eksentriset ja *Sphagnum fuscum* keitaat, 4) Pohjanmaan aapasuot, 5) Perä-Pohjolan aapasuot, 6) Metsä-Lapin aapasuot, ja 7) orohemiarktiset suot ja palsasuot. (Eurola et al. 1994)

Suot jaetaan kolmeen päätyyppiryhmään: rämeet, korvet ja avosuot, joista voidaan jakaa nevoihin ja lettoihin. (Laine ja Vasander 2008). Soilla olevat putkilokasvit ja sammaleet voivat vedenpinnan korkeuden määrittelyn mukaan kasvaa mätäspinnoilla, välipinnoilla ja rimpipinnoilla. Osa kasveista ovat valikoimattomia kasvupaikkansa suhteen eli vedenkorkeus



tai ravinteisuus eivät vaikuta kasvien tai sammalien esiintymiseen. (Eurola et al. 1994; Laine ja Vasander 2008)

Mätäspinnat ovat kuivia ja niissä veden pinta on yli 20 cm suon pinnan alapuolella. Lisäksi mätäspintojen pH-luku on yleensä alhainen. Mätäspinnoilla kasvaa ruskorahkasammalia. Ruskorahkasammaleisuus tarkoittaa *Sphagnum fuscum*-tyyppiä ja siihen liitetään määritelmä 'rahkaisuus'. Välipinnalla eli kosteapintaaisuudella tarkoitetaan lyhytkortisuutta, joka näkyy maastossa tupasvillan, rahkasaran ja tupasluikan vallitsevuutena. Vesipinta on välipinnoissa 5-25 cm syvyydellä. Rimpipinta tarkoittaa, että vesi on alle 5 cm pinnan alapuolella tai vesi peittää kasvupaikan kokonaan. Rimpisyys voi olla runsasta avosoilla. Rimpisyyden tyypillisiä kasvilajeja ovat mm. mutasara, raate, juurtosara, luhtavilla, rimpivihvilä, villapääluikka ja hetesirppisammal. (Eurola et al. 1994; Laine ja Vasander 2008)

Aapasoiden pitkät ja kapeat jänteet ovat mätäs- tai välipintakasvillisuutta ja patoavat rimpivesiä. Keidassoilla määritelmän mukaan jänteitä vastaavat kermi, jotka ovat rahkarämettä. Kulju puolestaan vastaa keidassuon rimpipintatasoa. Mätäs on kasvillisuudeltaan ja vesitasoltaan kuten jänne, mutta mätäs ei ole kapea ja pitkä. Aapasoiden nevat ovat väli- ja rimpipintaisia keskustavaikutteisia ja heikko-keskiravinteisia kasvillisuutta edustava suon osa. (Eurola et al. 1994)

Suokasvillisuuteen vaikuttaa kasvupaikan ravinteisuus eli trofia. Soilla trofiatasot eivät perustu biomassan tuottoon vaan ovat osa maaperän happamuus-kalsitrofia järjestelmää. Trofiatason köyhimpinä tasoina ovat sadevedestä ravinteita saavat suot tai suon osat kuten ombrotrofiset keidassuot tai rahkarämeet. Ravinteikkaimpina tasoina ovat ruohoiset suot ja letot. Näiden väliin jäävät mm. vähäravinteiset oligotrofiset keskustavaikutteiset suot. Keskiravinteisten eli mesotrofisten soiden kalsium pitoisuus on 3000-5000 ppm kuivaturvelitrassa samalla kun suoveden johtokyky on 25-40 mS/m. (Eurola et al. 1994)

## 2.2 Ilmastomuutos ja hiilen sitoutuminen soihin

Kokonaisprimäärituotanto (GPP) on kasvien yhteyttämisen sitomaa ilmakehän hiiltä. Kun kokonaisprimäärituotannosta vähennetään autotrofinen soluhengitys ja lehdistä hiilen sitomisen aikana haihtuva hiili, muodostuu (NPP) nettoprimäärituotanto. (Hyvönen et al. 2007) Nettoprimäärituotanto (NPP) on keskeinen mittari arvioitaessa ilmastomuutosta ja hiilitasetta. Nettoprimäärituotanto kasvaa, kun kasvillisuus sitoo enemmän hiiltä kuin

luovuttaa sitä. (Mellilo et al. 1993) Nettohiilenvaihto (NEE) muodostuu, kun nettoprimäärituotannosta vähennetään hajottajien heterotrofisessa yhdessä kuolleiden kasvien hajoamisprosessissa syntyvä ja takaisin ilmakehään pääsevä hiili. (Hyvönen et al. 2007) Suot ovat merkittäviä hiilen varastoja. (Gorham 1991)

Korkealla oleva pohjavesi aiheuttaa soiden hapettomissa oloissa tapahtuvan kasvien maatumisen, mikä sitoo hiiltä turpeeseen. (Clymo 1993) Pohjoisen havumetsävyöhykkeen ja subarktisen alueen soilla on merkittävä rooli hiilen kierrossa. (Gorham 1991) Pohjoisen havumetsävyöhykkeen ja subarktisen alueen soilla maapallon hiilivarannoista sijaitsee noin kaksi kolmasosaa. Tästä hiilen määrästä maaperään on sitoutunut noin kolmannes (Post et al. 1982; Gorham 1991). Hiilen sidonta on suurempaa pohjoisella pallonpuoliskolla kuin eteläisellä (Tans et al. 1990). Soiden kuivatus ja turpeen kerääminen vapauttaa hiilidioksidia ja metaania takaisin ilmakehään (Gorham 1991). Hiilidioksidin määrä ilmakehässä on kasvanut 1950-luvulta noin 300 ppm:stä (IPCC 2013) nykyiseen lähes 410 ppm. (La Quere et al 2018)

Jääkauden jälkeen pohjoisiin ja subarktisiin turvemaihin on sitoutunut 455 Pg hiiltä ( $1 \text{ Pg} = 10^{15} \text{ g}$ ). Vuosittaiseksi hiilen sitomaksi määräksi arvioidaan 0,076 Pg-0,096 Pg. Pohjoisilla soilla vuotuisessa fotosynteesissä sidottu hiilen määrä on keskimäärin suurempi kuin kasvien hajotuksessa vapautunut hiili. (Turunen 2003)

Kauppi et al (1997) arvoivat tutkimuksessaan, että yli kaksi kolmasosaa eli 4800 Tg Suomen ekosysteemien hiilivarastoista on sitoutunut turpeeseen. Turunen ja Valpola (2020) arvioivat turpeeseen sitoutuneeksi hiilen määräksi 4874-5284 Tg. Suomen ojittamattomien soiden hiilivarastoiksi vuonna 2015 arvioitiin 2365 Tg. (Turunen ja Valpola 2020), mistä 85% on varastoitunut kuivattamattomille aapasoille. Pitkän ajan hiilen kertymissuhde hiilen varastoitumisessa (LORCA) on huomattu olevan merkittävästi suurempi keidassoilla ( $26,1 \text{ g m}^{-2} \text{ yr}^{-1}$ ) kuin aapasoilla ( $17,3 \text{ g m}^{-2} \text{ yr}^{-1}$ ). Rahkaisilla soilla kertymissuhde ( $20,8 \text{ g m}^{-2} \text{ yr}^{-1}$ ) on yleensä suurempi kuin sekatyypin soilla tai avosoilla. (Turunen et al. 2002)

Korkeintaan parisadan vuoden ajan kertymästä käytetään termiä nykykertymä (RERCA). Nykykertymä vaihtelee vuosittain  $30\text{-}100 \text{ g m}^{-2} \text{ a}^{-1}$  välillä. (Turunen 2003) Tänä aikana syntynyt turve ei ole käynyt vielä läpi samanlaista hajoamista kuin vanhempi turve. Tämän takia pitkänajan kertymää ja nykykertymää ei voi verrata toisiinsa, sillä parin sadan vuoden aikana turpeen kertyminen ja samalla hiilen kertyminen ei ole voimakkaasti lisääntynyt. (Sähköpostikeskustelu 3.12.2020 Turunen J. ja Rauhala J.). Kun arvioidaan soiden hiilikertymiä, tulisi myös suon ikä ottaa huomioon. (Yu 2012; Turunen 2003)

Soiden hiilikertymään ja -poistumaan vaikuttavat alueellinen ilmasto, lämpötila, hydrologia, geokemia, biokemia ja kasvillisuus. Globaalin ilmastomuutoksen on arvioitu saavansa vaikutuksensa lämpötilan ja sadannan muutoksista, jotka edelleen vaikuttavat soiden hydrologiaan ja kasvillisuuteen. Hydrologiamuutokset voivat muuttaa soiden ravinteisuustasoa, mikä puolestaan näkyy suon pinnalla kasvillisuusmuutoksina. Kasvillisuusyhdyskuntien (suotyyppien) tunnistaminen onkin tärkeä osa arvioitaessa soiden ja turvemaiden osuutta kasvihuonepäästöihin.

Hiilen kertyminen erilaisilla suotyypeillä vaihtelee. Lyhytkorsi-, tupasvilla-, rahka-, keidasrämeillä ja lyhytkorsikalvakkanevalla keidassuovyöhykkeellä kertyminen on kaikkein tehokkainta ( $30\text{--}35 \text{ g m}^{-2} \text{ yr}^{-1}$ ). Heikointa kertyminen ( $15 \text{ g m}^{-2} \text{ yr}^{-1}$ ) on eteläisen aapasuovyöhykkeen varsinaisilla saranevoilla ja varsinaisilla rimpinevoilla. Hiilen kertyminen vaihtelee myös suokasvillisuusvyöhykkeittäin. Pitkän ajan hiilen kertymissuhde on havaittu suurimmaksi eksentrisillä rahkasuoalueilla ( $27,4 \text{ g m}^{-2} \text{ yr}^{-1}$ ) ja alhaisemmaksi ( $16,9 \text{ g m}^{-2} \text{ yr}^{-1}$ ) pohjoisella aapasuovyöhykkeellä, palsavyöhykkeellä ja orohemiarktisella suovyöhykkeellä. (Turunen 2002)

Hiilen kierrossa on havaittu vuodenaikaisvaihteluja, joissa selittävinä tekijöinä ovat mm. lumen määrä, pohjaveden pinnan taso sekä ilman että maaperän lämpö. (Daulaut ja Clymo 1998; Aurela et al. 2001; Wisser et al. 2011) Vesitaloudella on ratkaiseva merkitys turvemaiden hiilitasapainon kannalta. Suomen soilla tehdyissä tutkimuksissa on osoitettu, että yksittäinen kuiva ja lämmin kesä voi muuttaa luonnontilaisen suon hiilen lähteeksi jopa vuosiksi (Alm et al. 1999). Hiilen varastoja arvioitaessa on otettava huomioon turpeen paksuus ja turpeen kuiva-aines. (Tolonen 1979; Gorham 1991; Turunen et al. 2001)

Maailmanlaajuisen ilmastomuutoksen tunnusmerkkeinä pidetään muutoksia mm. sadannassa, haihdunnassa sekä maan ja meren pintalämpötiloissa. Maa-alueilla on havaittu enemmän lämpimiä päiviä ja öitä ja vastaavasti kylmät yöt ja päivät ovat vähentyneet. Lumen peittävyys maanpinnalla ja ikiroudan levinneisyys ja paksuus ovat pienentyneet (IPCC 2013). Ihmisen toiminta on arvioiden mukaan aiheuttanut noin  $1,0^\circ \text{ C}$  ilmaston lämpenemisen esiteollistumisen ajoista. Vuonna 2030 ilmaston oletetaan olevan  $1,5^\circ \text{ C}$  lämpimämpi kuin esiteollistumisen aikana. (IPCC 2018). Ilmastomuutoksen avainindikaattoreina ovat kasvihuonekaasut hiilidioksidi ( $\text{CO}_2$ ), metaani ( $\text{CH}_4$ ) ja dityppioksidi ( $\text{N}_2\text{O}$ ), jotka pitävät muutosta yllä (IPCC 2013) Ympäristöolosuhteissa tapahtuvat muutokset vaikuttavat

puolestaan hiilidioksidin

2,

4 ja

$^{12}\text{C}$  kiertoon. (Limpens et al. 2008;

Christensen et al. 2004; Elberling et al. 2010)

Ilmastoon vaikuttavien tekijöiden ja niistä aiheutuvien kemiallisten ja fysikaalisten prosessien ymmärtäminen auttaa kehittämään parempia ilmastomalleja. Tätä varten tarvitaan pitkän ajan mittauksia hiilen vaihdosta maan ja ilmakehän välillä, jotta ilmaston muutoksen vaikutuksia erilaisilla ajallisilla ja spatiaalisilla skaaloilla ymmärrettäisiin paremmin. (Aurela et al. 2009; Yu 2012)

Kun saadaan tarkempaa tutkimustietoa suotyyppien ja pientasotopografisten piirteiden ominaisuuksista kasvihuonekaasujen lähteinä tai nieluina, on mahdollista, että tulevaisuudessa myös luonnontilaisten soiden hiilitaseet huomioidaan kansainvälisessä kasvihuonekaasujen inventoinnissa.

Suomen soiden kokonaishiilitaseiden laskemista varten suotyyppien ja mikrotopografisten piirteiden kartoittaminen on tärkeää. Soiden kasvihuonekaasutaselaskelmissa käytettävät päästökertoimet riippuvat suokuvion ravinteisuustasosta, jotka voidaan yleistää suotyypeistä (Turunen et al. 2002) ja suon hydrologisesta tilasta eli pohjavesipinnan korkeudesta (Minkkinen et al. 2007). Kasvihuonekaasutaselaskelmien keskeinen pohjatieto onkin juuri kuviokohtainen paikkatieto suotyypeistä ja niiden ravinteisuustasoista.

Suomen soista on olemassa tutkimuslaitosten ja viranomaisten ylläpitäminä paikkatietaineistoja. Suomen ympäristökeskuksen sivuilta (SYKE 2020a) löytyy CORINE-maanpeiteluokittelu sekä maanpeite- ja rantakosteikot. Näissä aineistoissa on suot jaoteltu lehtipuuvaltaisiin, havupuuvaltaisiin, sekapuustoiisiin, harvapuustoiisiin ja avosoihin soihin (SYKE 2020). Maanmittauslaitoksen (MML 2020a) avoimien aineistojen tiedostopalvelusta löytyvät soistumat, sekä helppo/vaikeakulkuiset metsää kasvavat/puuttomat suot karttatasona koko Suomen alueelta. Metsähallitus vastaa valtion omistamien maiden luontotyyppien suojelusta (Metsähallitus 2020). Suoluontotyyppien arvioinnissa on luokiteltuna 50 suotyyppiä. (SYKE 2020b) Geologian tutkimuskeskuksella (GTK 2020) on turvevarojen kartoitusaineistoa sekä Luonnonvarakeskuksella (LUKE 2020) on valtakunnanmetsien inventointidataa soista (Luke VMI 12). Tiedot soista ja suotyypeistä ovat hajaantuneina eri tietokantoihin, joista vain osaan on avoin pääsy. Kaukokartoitusaineistojen ohjattu luokittelu on ainoa menetelmä, jolla pystytään kustannustehokkaasti luomaan koko Suomen kattava suotietokanta.

## 2.3 Kaukokartoitusmenetelmät

Kaukokartoitussensorit havainnoivat erilaisilla aallonpituuksilla olevia elektromagneettista eli sähkömagneettista säteilyä kosmisesta säteilystä radioaaltoihin (Jensen 1996; Lillesand et al. 2015). Säteilyä mittaavat laitteet voivat havainnoida auringon lähettämän säteilyn heijastumista kohteesta sensoreihin tai laitteet voivat itse aktiivisesti lähettää säteilyä kohteeseen, josta säteily palautuu sensoreihin (Lillesand et al. 2015). Yleisiä kaukokartoitusaineistoja ovat laserkeilausaineistot, ilmakuvat ja satelliittikuvat, jotka mittaavat näkyvän ja infrapuna-alueen säteilyä tai mikroaaltoalueen säteilyä; Lillesand et al. 2015)

Maanpeitteellä tai kohteella on oma tunnusomainen tapansa imeä säteilyä itseensä, tai heijastaa säteilyä takaisin ilmakehään, mitä suhdetta voi mitata kaukokartoitusinstrumentilla. Kohteen ominaisuuksia voi selvittää sen heijastaman tai lähettämän sähkömagneettisen säteilyn voimakkuuksien perusteella. Jokaisella kohteella on oma spektrinsä ja säteilyn heijastumisen intensiteetti eri aallonpituusalueilla, jonka avulla sen voi tunnistaa (Jensen 1996; Lillesand et al. 2015).

Taajuus on tietyn pisteen tietyssä ajassa ohittavien aallonhuippujen määrä, mikä ilmoitetaan hertseinä (Hz). Aallonpituus on taajuuden käänteisluku. Molemmat suureet kuvaavat säteilyn takaisin heijastuneen energian intensiteetin sijoittumista elektromagneettiseen spektriin. Optisella alueella aallonpituuden yksikkönä käytetään mikrometriä ( $\mu\text{m}$ ) tai nanometriä (nm). Takaisinsironneen energian määrästä kertoo irradianssi, mikä kuvaa saapuvan sähkömagneettisen säteilyn tehoa tietylle pinta-alalle. Irradianssin yksikkö on  $\text{W}/\text{m}^2$ . Radianssi on tarkkailtavasta kohteesta tiettyyn suuntaan jossakin kulmassa lähtevä säteilyteho. Radianssin yksikkö on  $\text{W}/\text{m}^2/\text{sr}$ . Reflektanssi eli heijastussuhde (tai -kerroin) ilmoitetaan prosentteina takaisin heijastuneen energian määränä verrattuna täydellisen heijastuksen määrään (Lillesand et al. 2015).

Sensorin mittaamien aallonpituuskanavien määrää ja leveyttä kutsutaan spektraaliseksi resoluutioksi eli erotuskyvyksi. Sensorin spatiaalinen erotuskyky tarkoittaa yhden kuvaelementin, eli pikselin pinta-alaa, jonka se rekisteröi tietyllä intensiteettiärvolla. Näkyvän valon eli optisen alueen aallonpituusalue on  $0,4\text{--}0,7\ \mu\text{m}$ , lähi-infrapunasäteilyn  $0,7\text{--}2,0\ \mu\text{m}$ , keski-infrapunasäteilyn  $2,0\text{--}5,0\ \mu\text{m}$ , ja pitkän infrapunasäteilyn eli lämpösäteilyn aallonpituusalue on  $8,0\text{--}15,0\ \mu\text{m}$ . Pikäaaltoinen infrapunasäteily läpäisee aallonpituudella  $5\text{--}$

8  $\mu\text{m}$  ja 14.20  $\mu\text{m}$  läpäisevät huonosti ilmakehän, ja siksi niiden käyttö on rajallista kaukokartoituksessa. (Jensen 1996; Lillesand et al. 2015)

Kaukokartoitusaineistoja esikäsitellään eri tavoilla ennen lopullista hyödyntämistä.

Tutkittavan kohteen pinnan kuvaamista voi rajoittaa erotuskyky. Radiometrinen resoluutio tarkoittaa laitteen kykyä mitata ja erottaa heijastuneen säteilyn intensiteettiero. Temporaalinen resoluutio tarkoittaa kuinka usein satelliitti ylittää saman paikan maanpinnalla. Aineistossa voi olla virheitä tai vääristymiä, jolloin tarvitaan erilaisia korjauksia;

- 1) geometrisia korjauksia, jolloin aineisto rekisteröidään karttakoordinaattijärjestelmään ja korjataan myös geometrisiä vääristymiä (Jensen 1996; Lillesand et al. 2015)
- 2) radiometrisiä korjauksia, jossa korjataan kuvausgeometrian, ilmakehän ominaisuuksien (Chavez 1996; Moran et al. 2001) tai topografian aiheuttamia spektraalisia vaikutuksia (Schaaf et al. 1994; Pellikka 1998)
- 3) laitteen aiheuttamia virheitä (USGS 2018)

Kaukokartoitusaineiston muuttaminen tarkaksi tiedoksi vaatii *in situ*, eli maastomittauksia (Jensen 1996; Schoepfer et al. 2008). Kaukokartoituksen tulkinnan apuna esimerkiksi luokittelussa ja uuden tiedon saamiseksi voidaan käyttää jo valmiita tutkimus- ja paikkatietoaineistoja (Pääkkönen 2006; Middleton 2014; Minasny et al 2019).

Satelliittikaukokartoituksen etuna on usein edullisuus, spatiaalinen ja ajallinen kattavuus sekä toistettavuus. Sen heikkoutena ilmakehän ja sään aiheuttamat vääristymät, ja se, että satelliitit eivät välttämättä ole oikeassa paikassa oikeaan aikaan. Lisäksi niiden tuottaman aineiston heikko spatiaalinen ja radiometrinen resoluutio heikentää niiden käytettävyyttä. Resoluutio vaihtelee esimerkiksi WorldView-1:n 0,55 metristä NOAA AVHRR/3 1,1 km:n pikselikokoon. Spatiaalinen, spektraalinen, radiometrinen ja temporaalinen erotuskyky on parantunut vuosikymmenien aikana (Lang et al. 2015).

Laserkeilaustekniikkaan perustuva LiDAR (Light Detection and Ranging) on aktiivinen kaukokartoitussensori, jota voidaan operoida lentokoneesta, lennokista tai maanpinnalta (Kareinen 2007). Sensorin ja kohteen välimatka lasketaan laserpulssin kulkemasta ajasta siitä, kun se lähetetään laserkeilaimesta siihen asti, kun takaisin sironneen pulssin signaali havainnoidaan jälleen keilaimen vastaanottimessa (Van Den Eckhaut et al. 2007).

Laserkeilauksen tuottaman pistepilven x,y ja z-koordinaatit tunnetaan (Kareinen 2007).

Kuvauskulma on yleensä  $10^{\circ}$  -  $20^{\circ}$  (Kareinen 2007). Ensimmäisiä kasvien latvuksista kimpoavia pulsseja kutsutaan latvuspulssiksi ja viimeisiä maanpinnasta kimpoavia paluupulssiksi (Van Den Eckhaut et al. 2007). Lasersäde on monokromaattista korkean energian valoa lähi-infrapunan alueelta. Suomessa Maanmittauslaitokselta saa avoimena aineistona koko Suomen kattavaa laserkeilauspistepilviaineistoa sekä siitä  $i2$  m pikselikokoon interpoloitua maanpinnan korkeusmallia (Maanmittauslaitos 2020). Laserkeilauksen etuna on, että sen hankinta ei ole samassa määrin riippuvaista säästä tai vuorokauden ajasta kuin ilmavalokuvaus, sillä pulssi läpäisee pilven, eikä tarvitse auringon valoa. Inertial Measuren Unit (IMU) ja Global Position System (GPS) avulla saadaan mittaushetkellä keilaimen tarkka sijainti ja asento selville. Mittauksen apuna voidaan käyttää maanpäällä olevaa tukipistettä eli referenssipistettä, josta lähetetään lentolaitteen GPS:ään differentiaalikorjausdataa. Navigointitarkkuus on noin kymmenen senttimetriä (Kareinen 2007).

Laserkeilausaineistossa on satunnaisia virheitä, karkeita virheitä ja systemaattisia virheitä. Oikeaan maanpintaan nähden mitatuilla pisteillä on satunnaisia jakaumia. Karkeita virheitä voi esiintyä maanpinnan suhteen johtuen joko mittausvirheistä tai vääristä heijastuksista. Systemaattiset virheet ovat joko karkeita tai vähäisiä (Kareinen 2007).

## 2.4. Soiden kaukokartoitus

Kaukokartoituksen merkitys boreaalisen vyöhykkeen suoalueiden rajaamisessa, turvemaiden puustoisuuden kartoittamisessa, suotyyppien tunnistamisessa ja soiden sisäisen ekologisen rakenteen kartoittamisessa on osoitettu useissa tutkimuksissa. Mikkolan ja Pellikan mukaan (2002) väärä - värikuvia on yleensä käytetty kasvillisuuden kartoitukseen, mutta nykyään käytetään multispektrisiä satelliittikuvia, hyperspektrikuvia, tutkakuvia ja laserkeilausaineistoista johdettuja kasvillisuuden ja maanpinnan korkeusmalleja. (Bourgeau-Chavez et al. 2018, Minasny et al. 2019) Minasny et al. (2019) selvittivät miten soita on kartoitettu 12:ssa maassa ja 90:ssä tutkimuksessa. Tutkimuksissa käytettiin kaukokartoitusta, kartoittamista, ekologiaa, tilastollisia malleja ja ympäristötutkimuksen kenttätutkimuksia, Tutkimuksissa harvemmin paneuduttiin validointiin ja mallien ennustavuuden epävarmuuksien laskemiseen (Misnay et al 2019).

Soiden kaukokartoitus on haasteellista, koska soiden ekologinen vaihtelu on usein pienimittakaavaista ja puustoisuus vaihtelee puuttomista avosoista metsäisiin soihin. Lisäksi

soiden ekologinen gradientti voi olla jyrkkä lyhyelläkin matkalla ravinteisuuden ja kosteuden vaihtuessa. Kaukokartoitusaineistojen spatiaalinen resoluutio on usein liian karkeaa kuvaamaan pienimittakaavaista kasvillisuuden vaihtelua, jolloin joudutaan turvautumaan joko hierarkkisesti korkean tason luokitteluun, unmixing luokittelumenetelmiin tai hyvin korkean resoluution kaukokartoitusaineistojen käyttöön hierarkkisesti matalan tason luokittelujärjestelmissä (e.g. Harris and Bryant 2009). Siirryttäessä hierarkkisella tasolla suon sisäiseen floristiseen luokitteluun ja käytetään tarkemman resoluution aineistoja, kuten ilmakuvia, laserkeilausaineistoa, lentokoneesta kuvattuja hyperspektriaineistoja tai SPOT satelliittikuvia, luokittelutarkkuus on yleensä 60–80 % (esim. Arkimaa et al. 2005, Huang ja Sheng 2005, Grenier et al. 2007). Tosin Dechka et al. (2002) tutkimus osoitti, ettei aineiston korkea spatiaalinen resoluutiokaan takaa onnistunutta luokittelua, vaikka käytetään hierarkkisesti korkean tason luokittelujärjestelmää. Luokkasisältöä optimoiden käytettyyn resoluution nähdessä käyttäen hyväksi kasvillisuuskartoitusta ja ordinaatio-menetelmiä voidaan saavuttaa korkeitakin (87,8 %) luokittelun luotettavuustuloksia (Middleton et al. 2012).

Soiden nettoprimäärituotannon mallinnusta varten Field et al. (1995) käytti AVHRR satelliittiaineistosta laskettua normalisoitua kasvillisuusindeksiä (Normalized Difference Vegetation Index, NDVI). Deerin ja Haas (1980) mukaan NDVI:n (Deering et al 1975) käyttö perustuu tietoon, että yhteyttämiseen tarvittava lehtivihreä absorboi näkyvää valoa samalla kun lehtien solurakenne heijastaa voimakkaasti lähi-infrapunavaloa. Tämän taustan perusteella NDVI lasketaan lähi-infrapun ja näkyvän valon punaisen aallonpituuksien suhteesta (NIR-RED/ NIR+RED). Mitä korkeampi NDVI-arvo, sitä enemmän kohteessa on lehtipinta-alaa (Jensen 1996).

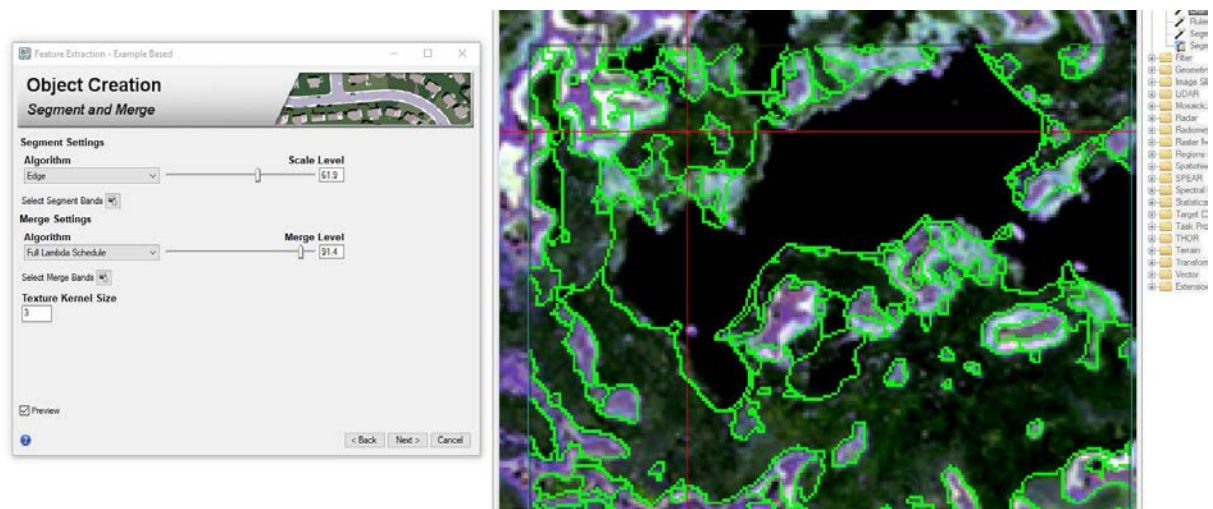
Mätäspintojen ja märkäpintojen luokittelua käytetään kategorisoimaan turvemaiden ekosysteemejä mikrotopografiatasolla. Käyttämällä esimerkiksi lennokista kuvatulle korkearesoluutioiselle aineistolle structure from motion (SfM)-menetelmää ja siitä luotua korkearesoluutioista korkeusmallia pystytään luokittelemaan soiden mikrotopografista vaihtelua sekä mikrotopografian muotojen ja rakenteen mahdollista roolia biogeokemiallisissa muutoksissa (Moore et al. 2019). Dribault et al. (2012) erotti kuusi eko-hydrologista nevaluokkaa sisältäen vesipinnat, eri kasvillisuusluokat, ja puustoluokat Kanadan Quebec’issä GeoEye-1 satelliittikuvasta 82 % luotettavuusasteella. Suon kasvillisuusluokkien ja soiden pientopografisten ominaisuuksien kartoitus korkean resoluution laserkeilauksella on osoitettu toimivan aapasoilla, joissa 21 suotyyppiä pystyttiin tunnistamaan 33-66% luotettavuudella ja 9 ravinteisuusluokkaa 59-81% luotettavuudella. (Korpela et al. 2009). Edellämainittujen



tutkimusten perusteella korkean resoluution satelliittikuvien ja laserkeilausaineiston yhdistelmän voidaan olettaa olevan tehokas aineistokokonaisuus soiden sisäisessä kasvillisuusluokittelussa.

## 2.5 Kaukokartoitusaineistojen kuvankäsittely ja soiden luokittelu

Kaukokartoituskuvien luokittelua voidaan tehdä joko pikselipohjaisesti tai objektipohjaisesti. Objektiperusteinen kuvankäsittelyä (Object-based image analysis, OBIA) käytetään silloin kun luokiteltavat kohteet muodostuvat useista pikseleistä. Satelliittikuvien kohdalla silloin ovat yleensä kyseessä korkean resoluution aineistot, joiden pikselikoko on 0.5 metristä muutamaan metriin. OBIA on semiautomatisoitu kuvankäsittelytekniikka, joka on vaihtoehto perinteiselle pikselipohjaiselle käsittelylle. Rasteriaineisto ensin segmentoidaan pikseliarvoiltaan homogeenisiin alueisiin eli objekteihin tai segmentteihin (Baatz et al. 2008). Tämän jälkeen pikseliarvojen lisäksi luokittelussa voidaan käyttää spektristen piirteiden lisäksi objektien muotoja ja naapuruussuhteita (Blaschke et al. 2008).



Kuva 1. Segmenttien muodostumisen tarkkuus keidassuolla

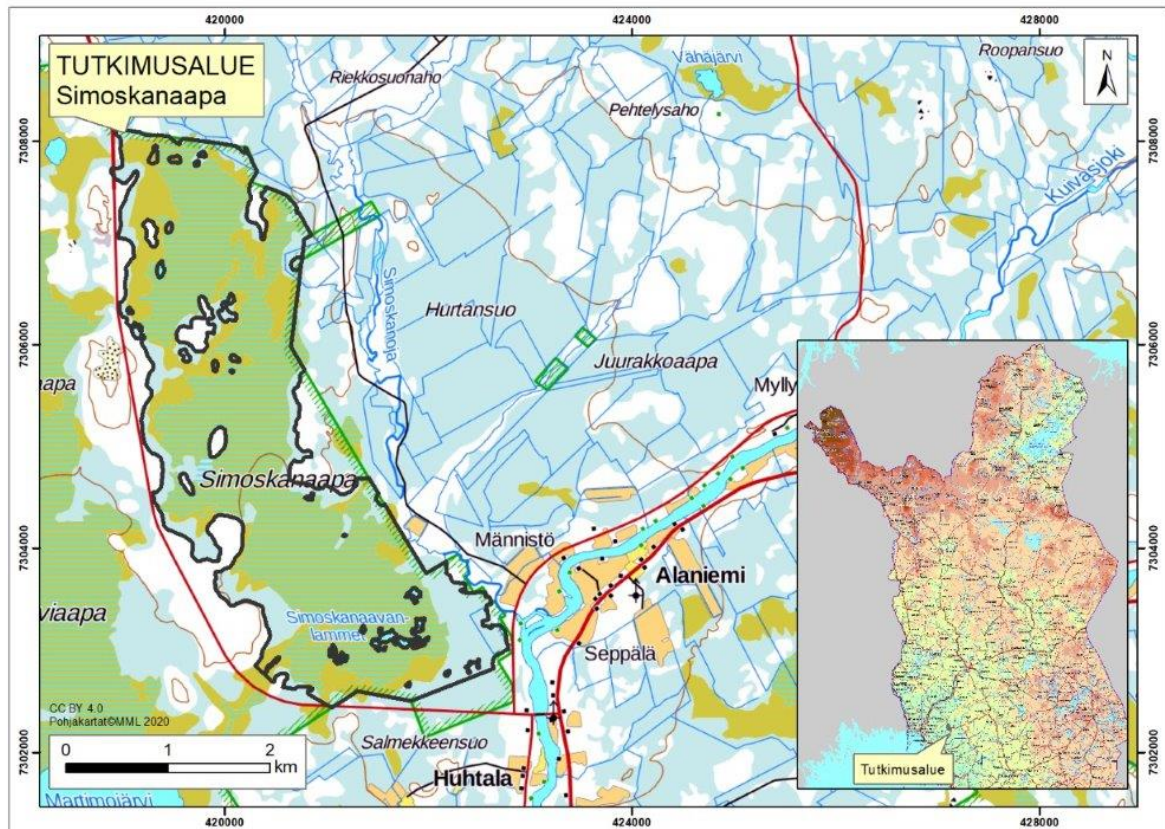
Objektiperusteista menetelmää on sovellettu myös viimeaikaisissa soiden kaukokartoitustutkimuksissa (Grenier et al. 2007, Dissanska et al. 2009, Bourgeau-Chavez et al. 2017). Grenier et al.'in (2007) tutkimus on esimerkki monivaiheisesta OBIA lähestymisestä, mikä johti jopa 76% luotettavuuteen. Dissanska et al. (2009) taas yhdistivät OBIA lähestymisen ja raja-arvoluokittelun korkean resoluution aineistojen käsittelyyn saaden jopa 81% luotettavuusarvoja.

Pikselipohjaisessa luokittelussa yleisesti käytetyt ohjatut luokittelumenetelmät voidaan yhdistää myös objektiperusteiseen kuvankäsittelyyn (Lillesand et al. 2015). Soihin kohdistuneiden tutkimusten (Grenier et al. 2007, Dissanska et al. 2009, Bourgeau-Chavez et al. 2017) perusteella voidaan päätellä, että objektiperusteinen kuvankäsittely ja Random forest-luokittelija ovat usein parhaimmat työkalut kaukokartoitusaineistojen tulkitsemiseen. Objektiperusteista lähestymistä voidaan soveltaa myös mittakaava-hierarkkisesti. Lopullinen luokittelustrategian valinta on kiinteästi sidoksissa käytössä oleviin aineistoihin.

### 3. TUTKIMUSALUE

#### 3.1 Tutkimusalue

Simoskanaapa sijaitsee Pohjanmaan-Kainuun aapasuovyöhykkeellä, jossa välipintaisten, lyhytkortisten soiden osuus on suurempi kuin muualla Suomessa (Eurola et al. 1994). Simoskanaavan tutkimusalue on pinta-alaltaan 1229 hehtaaria ja sijaitsee Simon kunnassa Etelä-Lapissa (N= 7304725, I=420568, Kuva 1). Simoskanaapa kuuluu Martimoaapa–Lumiaapa–Penikat-nimiselle Natura 2000 -alueeseen (Härkönen et al. 2010). Alueen suotyypit vaihtelevat karuista ombrotrofisista soista ravinteikkaisiin lettoihin (Härkönen et al. 2010). Metsähallituksen hoito- ja käyttösuunnitelman mukaan (Härkönen et al. 2010) Simoskanaapa on suuremmaksi osin aapasuot-Natura-luontotyyppiä, mutta etelä- ja kaakkoisosa on lähes kokonaan keidassuot-Natura-luontotyyppiä (Kuva 2). Aapasuo voi saada ravinnelisiä puronvarsista, suon reunaosista ja lumen sulamisvesien kautta. Keidassuo on keskeltään ympäristöään korkeampi ja ravinteet tulevat lähinnä sateena. (Eurola et al.1994).



Kuva 2. Simoskanaavan tutkimusalueen sijainti Pohjanmaan-Kainuun aapasuovyöhykkeellä Simon kunnassa.

Ilmatieteen laitoksen (2020) mukaan alueen terminen kasvukausi vuosina 1981-2010 on ollut 145-155 vuorokautta ja se alkaa toukokuun alussa ja loppuu lokakuun puoleen väliin mennessä. Tehoisa lämpösumma on 1000-1100 dd ja sadesumma 280-300 mm. Alueen kallioperä on graniittia (Suomen kallioperä DigiKP 2020) ja suon turve on määritetty paksuturpeiseksi (GTK 2020)

## 4. AINEISTO JA KÄSITTELY

### 4.1 Käytettävät kaukokartoitusaineistot

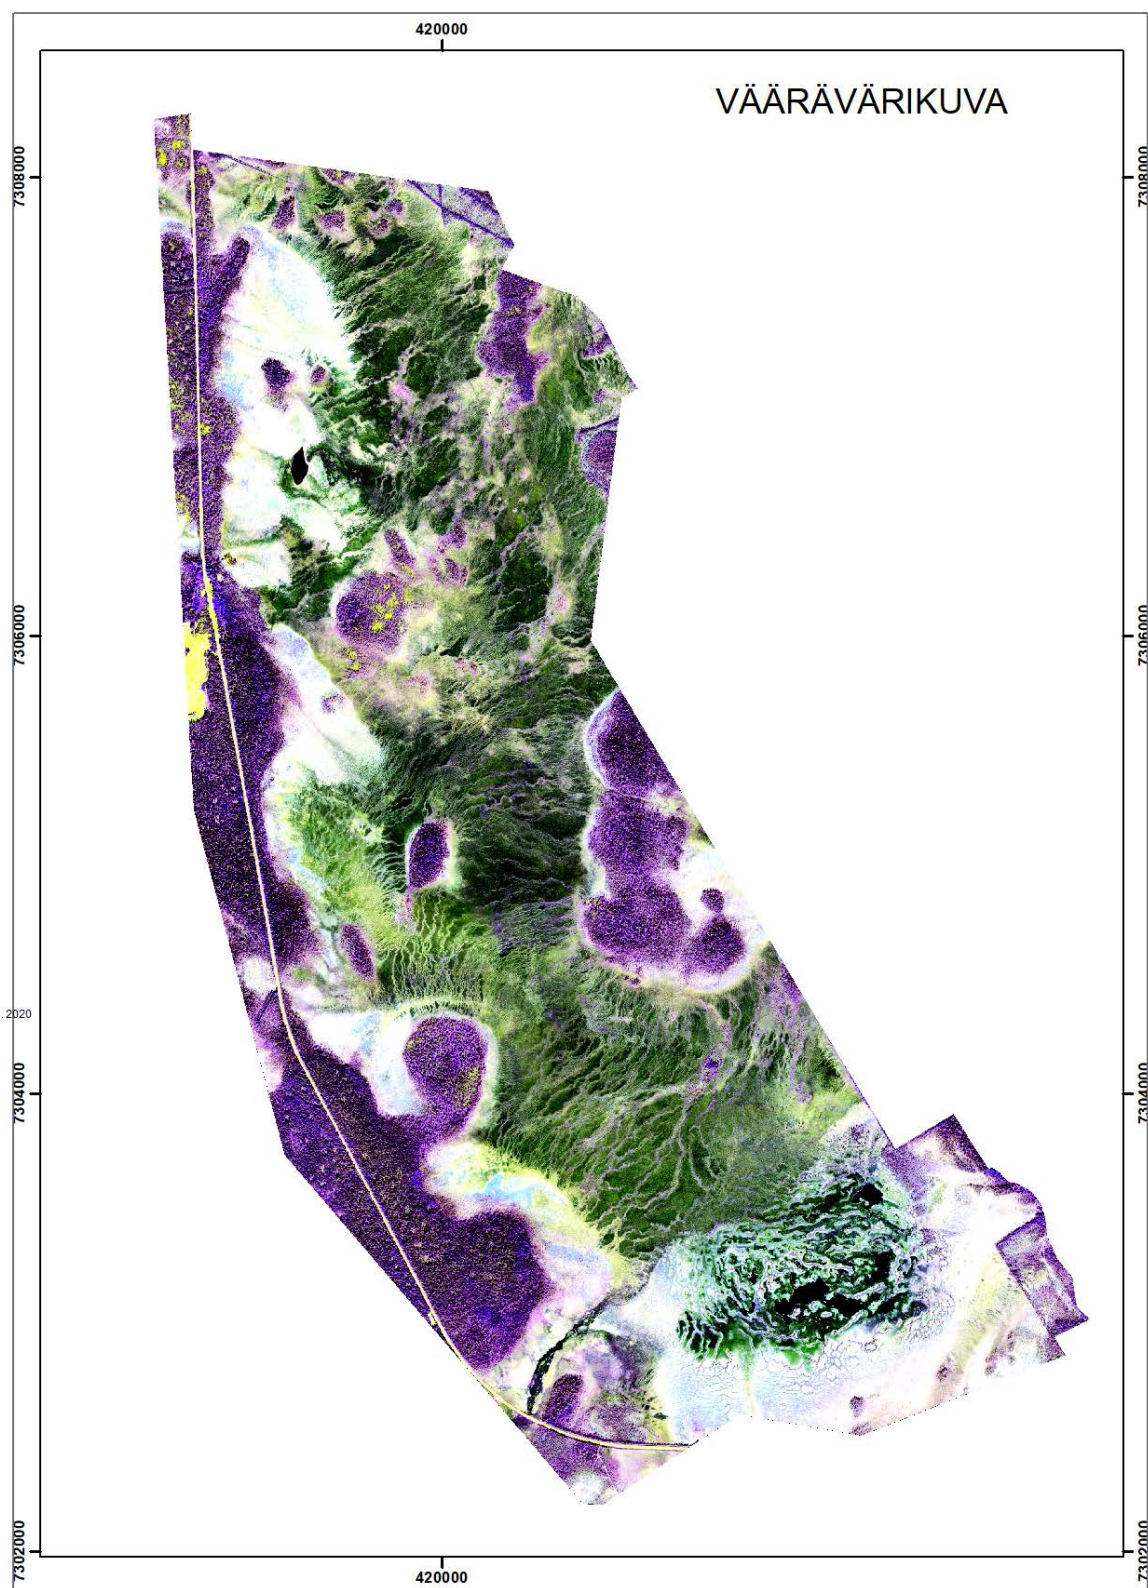
#### 4.1.1 WorldView-2

WorldView-2 aineistoa käytettiin tässä tutkimuksessa suon pinnan ominaisuuksia ilmentävänä kaukokartoitusaineistona. Se on kaupallinen kaukokartoitussatelliitti, jota operoi DigitalGlobe (Longmont, CO, USA). WorldView-2 satelliitti laukaistiin vuonna 2009 ja on sarjan toinen satelliitti. WorldView-2 kuvaa saman paikan 1,1 päivän välein 16,4 km leveällä mittauskaistalla. WorldView-2 satelliitissa on sensorijärjestelmä, jolla voidaan kuvata yksi pankromaattinen kanava 0,46 m resoluutiolla ja kahdeksankanavainen multispektraalinen aineisto 1,85 m resoluutiolla (taulukko 2). Tässä tutkimuksessa käytettiin neljää spektrikanavaa 1,6 m spatiaalisella resoluutiolla ja ne olivat sininen, vihreä, punainen ja lähi-infra. Aineisto saatiin käyttöön hakemuksella Euroopan avaruusjärjestöstä kolmannen osapuolien aineistoille (ESA 2020). Mukaan ei saatu pankromaattista kanavaa, jolla olisi voinut suorittaa terävöinnin pankromaattisen kanavan avulla. Kuva on otettu 22 heinäkuuta 2016.

Taulukko 2. WorldView-2 optisen satelliittiaineiston kanavat, joista tässä käytettiin sinisen, vihreän, punaisen ja lähi-infran kanavia.

Tutkimuksessa käytettyjen kanavien numerot	WorldView-2 kuvattavat kanavat	Aallonpituusalue (nm)	Spatiaalinen resoluutio (m)
	pankromaattinen	450-800	0,46
	Rannikon sininen	400 – 450	1,85
1	Sininen	450 - 510	1,85
2	Vihreä	510 - 580	1,85
	Keltainen	585 - 625	1,85
3	Punainen	630 - 690	1,85
	Red (Edge)	705 - 745	1,85
4	Lähi-infrapuna1	770 - 895	1,85
	Lähi-infrapuna2	860 - 1040	1,85





Kuva 3. Väärävärikuva WorldView-2 aineistosta Simoskanaavan tutkimusalueelta. Suon pohjoisosa on aapasuota, eteläosa keidassuota ja puustoa ja pensaikko sisältävä laide sijaitsee suon länsireunassa.

Luokittelua varten WorldView-2 kuvasta otettiin ns. väärä-värikanavat käyttöön. Näillä kanavilla kasvillisuus erottuu paremmin. Lehtipuut näkyvät erilaisin punaisin sävyin, koska pensaikat ja lehtipuut heijastavat enemmän lähi-infrapun aallonpituudella. Terve nurmikko tai ruohikko heijastaa kaikilla väärävärivärikuvassa käytetyillä aallonpituuksilla, ja eloton kuten rakennukset ja maa harmaan eri sävyinä (Lillesand et al 2015).

#### 4.1.2 Laserkeilausaineisto ja korkeusmalli

Maanmittauslaitoksen (MML) laserkeilausaineisto on mitattu vuonna 2010 (alue 48).

Aineiston pistetiheys on n. 0,5 pulssia neliömetrille (Maanmittauslaitos 2020b).

Pistepilviaineisto on ensin luokiteltu eri kohdeluokkiin, joista viimeiset paluupulssit on asetettu maanpintaluokkaan. MML on suorittanut käsittelyn Axelsson'in (2000) kuvaamaa rutiinia seuraten Terrasolid ohjelmistolla (Terrasolid Ltd., Helsinki, Finland). Lopulta maanpintapulssien korkeus merenpinnasta interpoloitiin 2 x 2 m korkeusmallirasteriaineistoksi. Korkeusmallin keskimääräinen vertikaali keskivirhe (root mean squared error, RMSE) on 0.3–0.4 m (Maanmittauslaitos, 2020b). Avoimen lähdekoodin korkeusmalli (Creative Commons 4.0 license) ladattiin MML avoimien aineistojen tiedostopalvelusta (Maanmittauslaitos 2020a).

#### 4.2.3 Vääräväri-ilmakuva-aineisto

MML:n ilmakuva-aineistoa käytettiin riippumattomana validointi- ja kalibrointiaineistona ohjatulle mikrotopografiselle luokittelulle. Digitaaliset vääräväri-ilmakuvat ovat lentokoneesta mitattua MML:n maastotietotuotantoon tuotettua lähtöaineistoa. Lopullinen digitaalinen vääräväri-ilmakuva prosessoidaan kahdeksan kameran muodostamista osakuvista. Pansharpening-tekniikalla väri-informaatio liitetään korkearesoluutioiseen pankromaattiseen kuvaan, minkä lopputuloksena saadaan kuva neljälle eri värikanavalle (punainen, sininen, vihreä ja lähi-infra). Aineiston sijaintitarkkuus riippuu kuvauskorkeudesta ja käytetystä


kamerasta. Aineiston geometriset virheet johtuvat maaston korkeuseroista ja keskusprojektiosta, jonka johdosta vääristymä on suurimmillaan kuvan reunoilla ja pienimmillään kuvan keskellä (Pellikka 1998, Maanmittauslaitos 2020c). Näillä virheillä ei ollut merkitystä tässä tutkimuksessa, koska aineistoa käytettiin luokittelun tueksi. Avoimen lähdekoodin ilmakuva (Creative Commons 4.0 license) ladattiin MML:n avoimien aineistojen tiedostopalvelusta (Maanmittauslaitos 2020a).

### 4.3 Kuvankäsittely ja luokittelumenetelmät

#### 4.3.1 TDR

Suon mikrotopografisten ominaisuuksien havaitsemiseksi MML:n 2 m korkeusmallista laskettiin TDR derivaattamuunnos (tilt derivative, Miller and Singh 1994; Verduzco et al. 2004) Oasis-ohjelmistolla (Geosoft Inc., Toronto, Canada). TDR:n edut verrattuna useisiin muihin yleisesti visualisoinnissa käytettäviin korkeusmallin suodatuksiin on se, että TDR:ssä ei ole suuntavaikutusta ja se normalisoi korkeuden vaikutuksen tuoden samalla tavalla esille matalat ja korkeat muodostumat (Middleton et al. 2020). Mikrotopografisia muotoja korostetaan TDR -muunnoksella, koska topografia-anomaliat, eli ympäristöstään erottuvat koverat, tasaiset ja kuperat muodot rajoittuvat arvovälille  $-90^{\circ}$ – $90^{\circ}$ . Teoriassa mikrotopografiset muodot voidaan eristää tasaisesta ympäristöstään käyttämällä TDR:n nolla-arvoa, joka sijoittuu lähelle rinteen ja sen viereisen alueen murtokohtaan (brakepoint). Kuva 3d esittää TDR arvon Simoskanaavan tutkimusalueelta keidassuolta ja aapasuolta. Visualisoitaessa TDR:ä huomattiin, että aineisto sisältää paljon spatiaalista kohinaa. Leveät kermit erottuvat keidassuoalueella, mutta aapasuolla jänteet ovat kapeita erottuen TDR-kuvasta erittäin heikosti (Kuva 3).





Kuva 4. Simoskanaavan koillisosan aapasuo ja keidassuo a) korkeusmallista lasketusta TPI, b) TDR, sekä WorldView-2:n c) kasvillisuusindeksi NVDI, sekä kanavat d) vihreä, e) punainen ja f) lähi-infrapuna.

#### 4.3.2 Topografinen positio-indeksi

Korkeusmallista laskettiin lisäksi topografinen positio-indeksi (TPI, Topographic Position Index), joka kuvaa kunkin pikselin suhteellista sijaintia annetulla säteellä. TPI lasketaan ottamalla keskiarvo korkeusmallista liikkuvan ikkunan alla ja vähentämällä tämän keskiarvo alkuperäisestä korkeusarvosta (Gallant ja Wilson 2000). Korkeuden keskiarvo laskettiin 10 metrin säteellä. Tätä ennen korkeusmallista poistettiin kohinaa laskemalla 3x3 pikselin keskiarvo. TPI:n laskenta tehtiin ArcGIS Pro-ohjelmiston versiolla 2.6.3 (ESRI Inc., Redlands, USA). Negatiiviset TPI arvot kuvaavat sijainteja, jotka ovat ympäristöönsä nähden alempana (koveria), ja positiiviset TPI arvot kuvaavat alueita, jotka ovat ympäristöönsä nähden korkeammalla (kuperia). TPI arvo erityisesti tuo esille jänteitä/kermejä, jotka erottuvat korkeina arvoina ympäröivästä tasaisesta suon pinnasta (Kuva 3a). Korkeusmalli, TDR, TPI sekä WorldView-2 aineiston 4 kanavaa yhdistettiin yhdeksi monikanavaiseksi tiedostoksi 2 m pikselikoossa ennen objektiperusteista luokittelua.



#### 4.3.3 Objektiperusteinen kuvan segmentointi

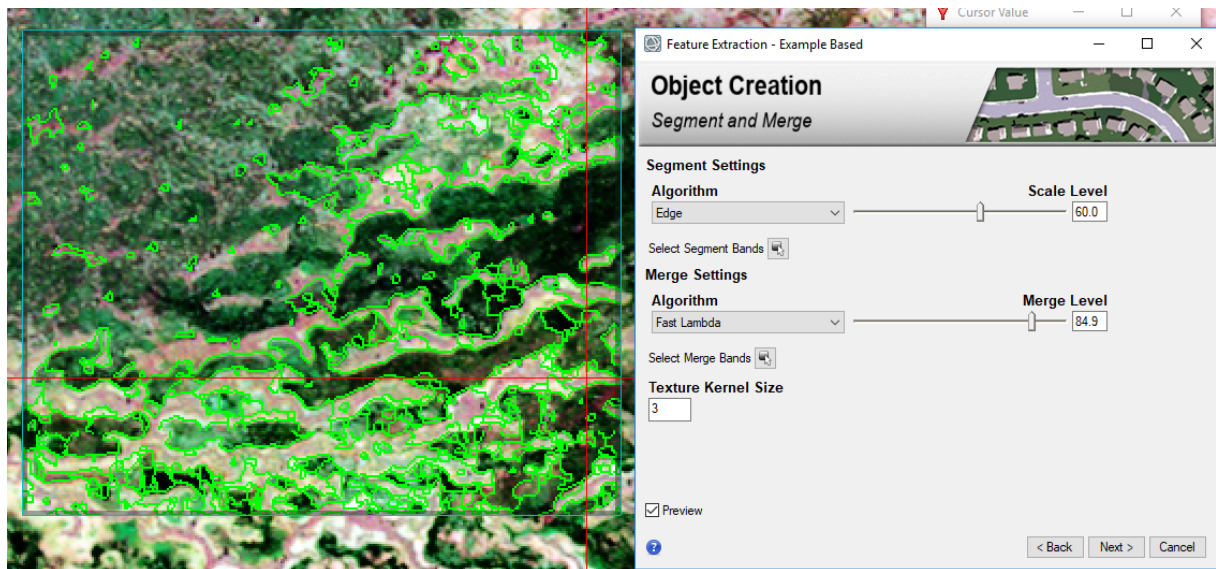
Objektiperusteinen luokittelu valittiin mikrotopografisten muotojen kuvankäsittely- ja luokittelumenetelmäksi, koska jänteet/kermit, suon märkäpinnat, allikot ja välipinnan muodostavat visuaalisesti selkeitä yksiköitä WordView-2 kuvalla ja korkeusmallilla.

Objektiperusteinen luokittelu suoritettiin ENVI kuvankäsittelyohjelmiston versiolla 5.6 ja siinä olevalla lisäosalla Feature Extraction (Harris Geospatial Solutions, Boulder, USA).

Feature Extraction on grafiikkapohjainen velho (workflow), joka perustuu kaksivaiheiseen automatisoituun prosessointiin. Velho ohjaa käyttäjää etenemään ensin läpi objektiperusteisen segmentointi ja sen jälkeisen luokitteluvaiheen. Segmentointi on patentoitu menetelmä perustuen 'valuma-alue segmentointiin' (watershed segmentation, Jin 2012) ja se koostuu seuraavista vaiheista:

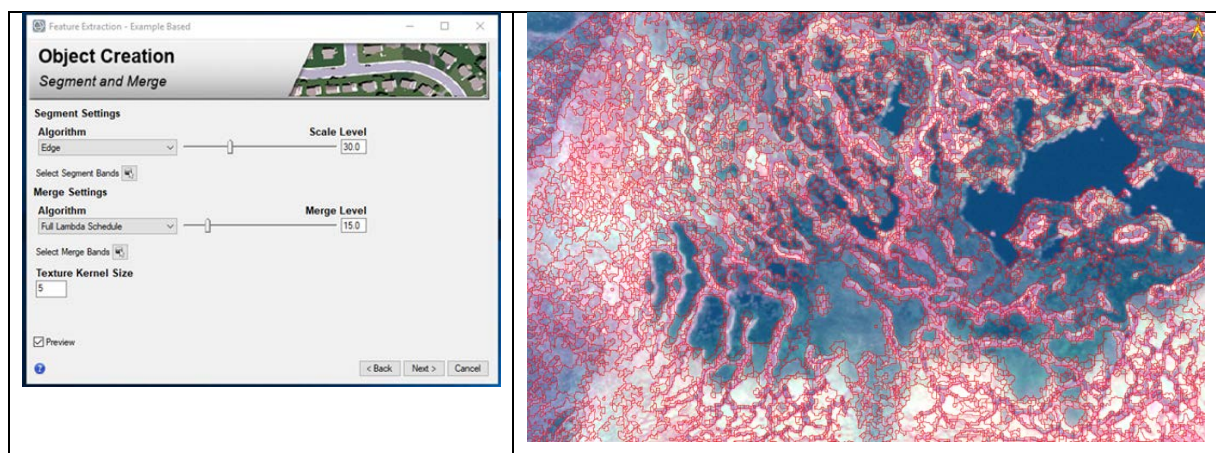
- 1) Lasketaan kaltevuus- tai intensiteetti kuvasta
- 2) Lasketaan kumulatiivisesti jakauma funktio kartasta
- 3) Muokataan karttaa käyttämällä valittua skaalausarvoa
- 4) Segmentoidaan modifioitu kartta käyttämällä valuma-alue-transformaatiota.

Valuma-alue transformaatio perustuu valuma-aluemalliin. Valuma-alue mallissa kuvitellaan, että alue täyttyy vedellä matalimmasta kohdasta lähtien. Pato rakennetaan kohtaan, missä useampienvalluma-alueiden vedet kohtaavat. Alueet, jotka jaetaan patojen jakamiin alueisiin, sanotaan valuma-alueiksi. (Roerdink and Meijster 2001). Samanlaista prosessia käytetään mm. digitaalisessa kuvantamisessa. Mitä tummempi pikseli on, sitä matalampi on korkeusarvo. Tämä pikseli on minimiarvo. Valuma-alue algoritmi lajittelee pikselit nousevalla arvoilla harmaasävyllä. Tuloksena syntyy segmentoitu kuva, jossa jokaisella segmentillä on tallennettuna ominaisuustietona pikselien spektri-arvojen keskiarvot kullekin kanavalle.



Kuva 5. Segmentointiesimerkki keidasrämeeen kermeistä ja välipinnoista

Segmentoinnissa määriteltiin kaksi parametria yrityksen ja erehdyksen kautta: kernelin koko (kernel size) ja mittakaavataso (scale level). Näiden parametrien avulla voidaan määrittää syntyvien segmenttien koko. Segmentoinnissa pyrittiin mahdollisimman kokonaisia mikrotopografisia muotoja rajaaviin segmentteihin, mutta kompromisseja jouduttiin tekemään, jotta segmentit eivät olisi tulleet liian suuriksi. Lopulta päädyttiin tekemään huomattavasti pienempiä segmenttejä kuin varsinaiset lopulliset objektit käyttäen mittakaavaparametriä 30 (Kuva 4). Objektien yhdistämistä tehtiin varovasti, jotta segmenttejä ei häviäisi liikaa. Segmentointi ajettiin aapasuo- ja keidassuoalueelle erikseen, koska yhteisiä segmentointiparametrejä ei pystytty näille määrittämään.



Kuva 6. Segmentointiparameterien valinta ja segmentointitulokset keidassuoalueella Simoskanaavalla ENVI Feature Extraction -velhossa.

Kuvassa 5 ja kuvassa 6 esitetään Scale-toiminnon ja Merge toiminnon arvojen vaikutuksen segmentointiin.

Taulukko 3. Segmentointiparametrit.

	Algorithm	scale	merge
Keidassuo	Edge	30	15
Aapasuo	Edge	30	15

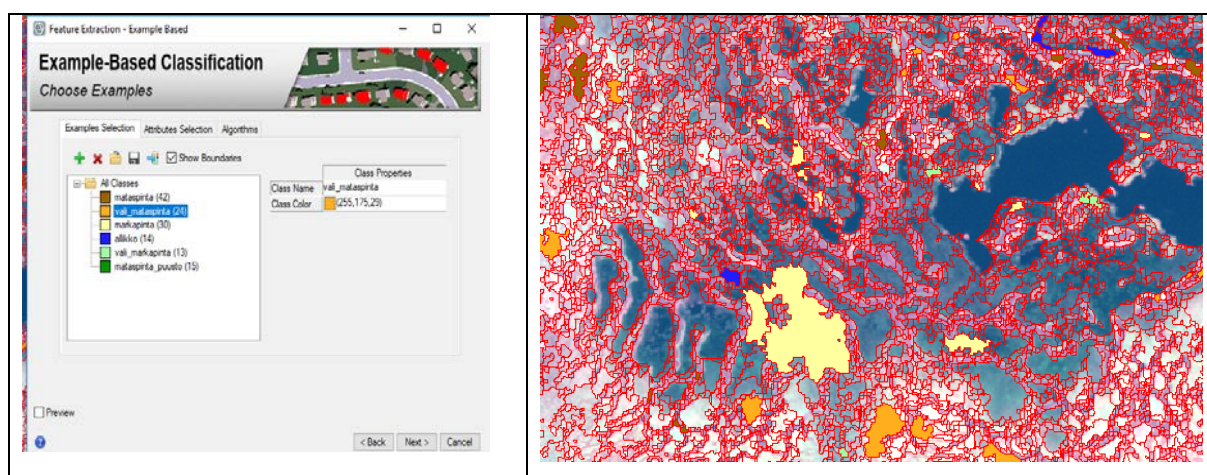
#### 4.3.4 Mikrotopografisten luokkien valinta

Opetusalueiden valinta perustui ilmakuvan visuaaliseen tulkintaan, johon pystyttiin tukeutumaan, koska tulkitsijalla oli työkokemus aapasoiden mikrotopografisista luokista. Keidassuon luokiksi valittiin mätäspinta, väli-mätäspinta, väli-märkäpinta, märkäpinta, mätäspintapuusto ja allikko. Aapasoilla luokiksi valittiin samat luokat lukuun ottamatta allikkoa. Hierarkkisesti tarkempaa luokittelutasoa, jossa kokeiltiin erikseen määrittää aapasuon jänteet ja keidassoihin ja kermeihin. Visuaalisesti tulkittuna luokittelutulokset olivat heikkoja luokkien sekoittuessa mm. mätäspintaan ja väli- ja märkäpintaan.

Keidasuolta valittiin luokittain opetusaineistoksi ne segmentit, jotka näyttivät olevan kokonaan samaa luokiteltavaa luokkaa. Muutamit segmentit näyttivät kuuluvan useampaan luokkaan, joten niitä ei otettu opetusalueiksi. Opetusalueita otettiin ympäri tutkimusalueetta. Suurin määrä oli mätäspintaluokasta, yhteensä 42 kappaletta. Koska tutkimuksen yksi tarkoitus oli erottaa pitkät rahkaiset kermit, valittiin väli-märkäpintatasolta 24 segmenttiä. Nämä olivat segmentoituneet isoimmiksi alueiksi. Valinnassa painotettiin kermin ja märkäpinnan väliin erottuvaa kapeaa kaistaletta. Märkäpintatasolta otettiin opetusalueiksi 30 segmenttiä. Märkäpinnat olivat myös hyvin selvästi segmentoituneet. Allikoiden (14 kpl) määrittämisessä käytettiin apuna korkearesoluutioista ilmakuvaa; sillä osa satelliittikuvissa olleista allikoista ei näkynyt ilmakuvassa. Valinnassa hyväksyttiin vain varmana pidetyt allikot. Mätäspintapuustoluokan tukialueet (15 kpl) valittiin alueen reunoilta ja muutamilta poismaskattujen metsäsaarekkeiden reuna-alueista. Väli-märkäpinnaksi muodostui piensaraisuuden ja saraisuuden johdosta kuvalla turkoosina alueet.

Aapasuon segmentointi erotti mätäspintapuuston (16 kpl opetusalueita) ja mätäspinnan (15 kpl opetusalueita) suon laidoilta hyvin. Samoin märkäpinnat olivat suuremmaksi osaksi segmentoituneet hyvin lukuun ottamatta suon keskiosan alle pikselin kokoisia alueita (118 kpl

opetusalueita). Väli-mätäspintataso ja välimärkäpintataso olivat ongelmallisempia. Opetusalueita määritettäessä piti ratkaista, onko aapasuon ruskean punaisena näkyvät jänneet rahkaisuuden ja välipintaisuuden hallitsemia jänneitä vai tuliko väri pensaista tai varvuista. Luokitus ratkaistiin siten, että väli-mätäspintaa tuli 128 kappaletta opetusalueeksi ja väli-märkäpintaa 10 kappaletta. Väli-märkäpinnaksi tuli käytännössä märän suon keskiosan pienet muutaman pikselin kokoiset osat.



Kuva 7. Opetusalueiden valinta Simoskanaavan keidassuoalueella ENVI Feature Extraction velhossa.

Taulukko 4. Simoskanaavan aapasuo ja keidassuo eri mikrotopografiset luokat.

Luokat	Aapasuon luokka	Keidassuon luokka
Mätäspinta	Aapasuo – mätäspinnat	Keidassuo –kermi, mätäspinta
Mätäspinta-Välipinta	Aapasuo –välipinta-jänne	Keidassuo - mätäspinta
Märkäpinta	aapasuo-rimpipinta	Keidassuo – kulju
Mätäspintapuusto	Puustoa tai pensaista sisältävät suot	Puustoa tai pensaista sisältävät suot
Vesi	–Ei ollut	Keidasuo - allikko
Välipinta-märkäpinta	Aapasuon märkäpinta-välipintatasot	Keidassuon märkäpinta-välipintatasot

#### 4.3.5 Objektien luokittelu tukivektorikoneilla

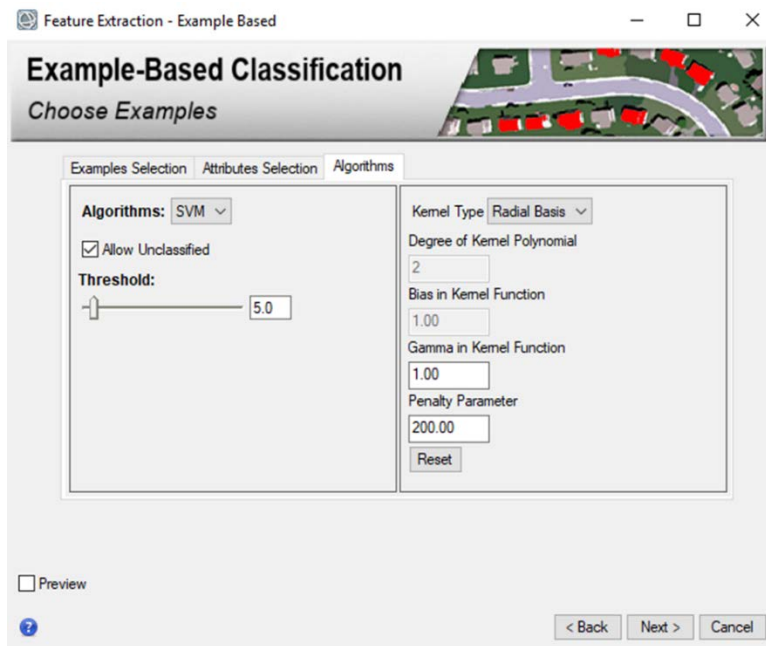
Ohjattuun luokitteluun käytettiin Feature Extraction velhon sisältämää tukivektorikoneetta (Support Vector Machine, SVM, Wu et al. 2004). SVM on tilastolliseen opetusmalliin perustuva ohjatun luokittelun metodi. Se soveltuu monimutkaisille ja kohinaa sisältävälle aineistolle. ENVI:n tukivektorikonealgoritmi perustuu LIBSVM-kirjastoon (Chang ja Lin 2011). SVM luokittelussa käytettiin epälineaarista Radian basis funktiona.

Tukivektorikoneluokittelijaa käytettäessä säädettäviä parametrejä ovat gamma ja rangaistus (penalty): 1) Kernel Funktion Gamma kentässä asetetaan käytettävät parametrit, 2) Määritellään SVM alogritmille rangaistusparametri.

ENVI:n SVM-käyttää Kernel-funktiota, mikä on epälineaarinen tiheysfunktio. Käytettävissä olevat Kernel-funktiot ovat lineaarinen, polynomial, RBF ja sigmoid. Gamma on yksi suodatusfunktioista, jossa alkuperäinen arvo korvataan niillä ympärillä olevilla pikseleiden arvoilla, jotka täyttävät keskihajonnan kriteerit tarkoittaen, että arvojen täytyy olla gammajakaantuneet. (Harris 2020c)

SVM alogritmin rangaistusparametri sallii tietyn asteen väärin luokittelun, esimerkiksi opetusalueilla saa olla virheitä tietyissä rajoissa. Nostamalla tai laskemalla tätä arvoa voidaan määrätä, kuinka hyvin otetaan huomioon luokittelemattomat kohdat. Tämä vaikuttaa mallin tarkkuuteen, jolloin malli on joko tiukasti rajoja noudattava tai yleistävä (Hsu et al. 2010).

Radial basis function käytetyt parametrit olivat: 1.0/3.0 (1947/2003) gamma, 300/100 rangaistusparametri ja 0.30/0.30 todennäköisyys raja-arvot. Luokittelun tulos näytetään esikatseluikkunassa. SVM funktion raja-arvon luotettavuus määrää, miten segmentti luokituu lähimpään segmenttiin edustaen samaa luokkaa. Korkeat arvot merkitsevät enemmän luotettavuutta, jolloin vain lähemmät segmentit luokitellaan. Alhaiset arvot merkitsevät epävarmuutta luokittelussa ja sitä edustavatko lähimmät naapurit samaa luokkaa, jolloin otetaan luokitteluun mukaan kauempina olevia segmenttejä. Arvoa pienennettäessä esikatseluikkunaan tulee vähemmän luokittelemattomia segmenttejä (Harris 2020d) (Kuva 6)




Kuva 8. Esimerkki SVM-algoritmille valituista funktion asteista ja raja-arvoista.

Automaattista attribuutINVALINTATYÖKALUA (automated attribute selection) käytettiin valitsemaan luokittelun kannalta merkitsevimmät spektraaliset, topografiset, tekstuuriset ja spatiaaliset muuttujat. Automaattinen attribuutINVALINTATYÖKALU valitsi tilastojen laskentaan spektraalisista arvoista keskiarvon, minimin, maksimin ja keskihajonnan. Tekstuurista työkalu valitsi kanavittain keskiarvon, varianssin ja entropian. Spatiaalisiksi muuttujiksi työkalu valitsi kanavittain pinta-alan, pituuden, kompaktisuuden, kaarevuuden, suurimman pituuden sekä pienimmän pituuden. (Harris 2020b)

Spektraalisille arvoja varten lasketaan jokaisella kanavilla erikseen pikseleiden keskiarvo, minimiarvo, maksimiarvo ja keskihajonta. Tekstuuria varten lasketaan pikseleille keski-arvot, keskimääräinen varianssi ja keskimääräinen entropia Kernel-funktion sisällä olevalle alueelle. Pinta-ala tarkoittaa polygonin alaa, josta on vähennetty aukot. Käsiteltävän kuvan ollessa pikseliperustainen, lasketaan pinta-alaksi segmentin pikselit ja pituudeksi pikseleiden määrä. Georeferoidulle kuvalle käytetään kuvan resoluution pinta-alayksikköä. Pituus tarkoittaa rajojen pituutta, mukaan lukien aukkojen rajat. Georeferoidulle kuvalle käytetään kuvan resoluution pinta-alayksikköä. Kompaktisuus tarkoittaa polygonin muotoa siten, että ympyrä on kaikkein kompaktein alue ja saa arvon  $1/\pi$ . Polygonin kompaktisuus lasketaan ottamalla neliöjuuri kaavasta  $(4 * \text{polygonin ala} / \pi) / (\text{uloimman rajaviivan pituus})$ . Convexity tarkoittaa polygonin kupertuutta kai koveruutta. Polygoni on kupera, kun se saa arvon 1.0 ja kun arvon



Käytetyt WordView-2 kanavat olivat vihreä, punainen, NIR ja NDVI, sekä korkeusmallista laskettu TPI.



Luokittelujen luotettavuutta arvioitiin virhematriisiin avulla, josta laskettiin luotettavuutta kuvaavia lukuja: luokkakohtaiset tuottajan tarkkuusarvot ja käyttäjän tarkkuusarvot sekä luokittelun kokonaistarkkuus. Tarkkuusanalyysi suoritettiin ENVI-ohjelmiston Confusion Matrix Using Ground Truth Roi-työkalulla. Laskentaa varten ilmakuvalta rajattiin luotettavuuden testaamista varten riippumattomat testialueet, jotka eivät sisältäneet opetusalueiden kanssa samoja pikseleitä. Testialueiden rajaamiseen avattiin toiselle näytölle ENVI-ohjelmisto ja siihen aukaistiin Confusion Matrix Using Ground Truth Roi-työkalulla

opetusalueet segmentteineen, millä vältettiin päällekkäisyydet testialueiden ja opetusalueiden välillä. Luokituksen luotettavuus määritettiin erikseen keidassuolle että aapasuolle.

Virhematriisissa esitetään testialueiden pikseleiden määrät, mitkä kartalla menevät päällekkäin luokittelutuloksen kanssa (Taulukko 5). Matriisin diagonaalille asettuvat oikein luokituneet pikselit. Niiden summa jaettuna kaikkien pikseleiden summalla on kokonaistarkkuusprosentti (Pellikka 1998). Kappa-kerroin kertoo myös luokittelun ja todellisen arvon yhtäpitävyyden. Kappa-arvo yksi tarkoittaa täydellistä yhtäpitävyyttä, kun taas kappa-arvo nolla tarkoittaa, että luokittelu ei ole ennustanut yhtään pikseliä oikeaan luokkaan. Tuottajan luotettavuudella tarkoitetaan todennäköisyyttä, että luokka on luokiteltu oikein tuottajan näkökulmasta. Käyttäjän oikeellisuudella taas tarkoitetaan todennäköisyyttä sille, että luokiteltu pikseli kuuluu annettuun luokkaan luokittelutuloksen käyttäjän näkökulmasta. (Congalton 1991; Lillesand et al. 2015; Harris 2020b)

Taulukko 5. Keidassoiden mikrotopografisten muotojen objektiperusteisen luokittelutuloksen virhematriisi, jossa numerot ovat pikselimääriä.

	Testialueet							
Luokittelu	Mätäspinta	Väli-mätäspinta	Märkäpinta	Allikko	Väli-märkäpinta	Mätäspinta-puusto	Summa	Käyttäjän tarkkuus %
Luokittelematon	0	0	0	0	0	0	0	
Mätäspinta	<b>312</b>	111	26	0	0	954	503	62,0
Väli-mätäspinta	6	<b>537</b>	9	189	92	0	833	64,5
Märkäpinta	1	8	<b>4135</b>	36	127	16	4323	95,7
Allikko	0	0	14	<b>35</b>	0	0	49	71,4
Väli-märkäpinta	0	0	188	11	<b>122</b>	94	415	29,4
Mätäspinta-puusto	0	0	6	0	0	<b>76</b>	82	92,7
Summa	319	656	4378	271	341	240		
Tuottajan tarkkuus %	97,8	81,8	94,5	12,9	35,8	31,7		



## 5. TULOKSET

### 5.1 Keidassuon luokittelu

Keidassoiden luokittelulle kuuteen mikrotopografiseen luokkaan saatiin kokonaisluotettavuudeksi 84,1% ja kappa-arvoksi 0,672. Taulukossa 6 on koottuna kunkin luokan tuottajan ja käyttäjän tarkkuudet kullekin luokalle. Liitteessä 1 on esitetty keidassuon Luotettavuusmatriisi.

Taulukko 6. Tuottajan ja käyttäjän tarkkuudet keidassoiden luokittelulle kuuteen mikrotopografiseen luokkaan.

	Mätäspinta	Väli-mätäspinta	Märkäpinta	Allikko	Väli-märkäpinta	Mätäspintapuusto
Tuottajan tarkkuus	97,8	81,8	94,5	12,9	35,8	31,7
Käyttäjän tarkkuus	62,0	64,5	95,7	71,4	29,4	92,7

Simoskanaavan tutkimusalueen keidassuon pinta-ala on 215 hehtaaria. Luokittelemattomia alueita oli 10% koko pinta-alasta eli 23 hehtaaria. Tämä voi johtua opetusalueiden riittämättömyydestä tai kuvassa oli pikseleitä, jotka eivät olleet saaneet arvoja. Mätäspintaa oli 50 ha eli 23%. Allikoiksi luokitui alle prosentti pinta-alasta eli 0,02 ha. Märkäpintaa oli 9% pinta-alasta eli 20 hehtaaria. Mätäspintapuustoa oli 13% pinta-alasta eli 30 hehtaaria. Väli-märkäpintaa oli viidennes pinta-alasta eli 41 hehtaaria. Väli-mätäspintaa oli neljäs pinta-alasta eli 51 hehtaaria. Kuvassa 8 esitetään kartta mikrotopografisista luokista.

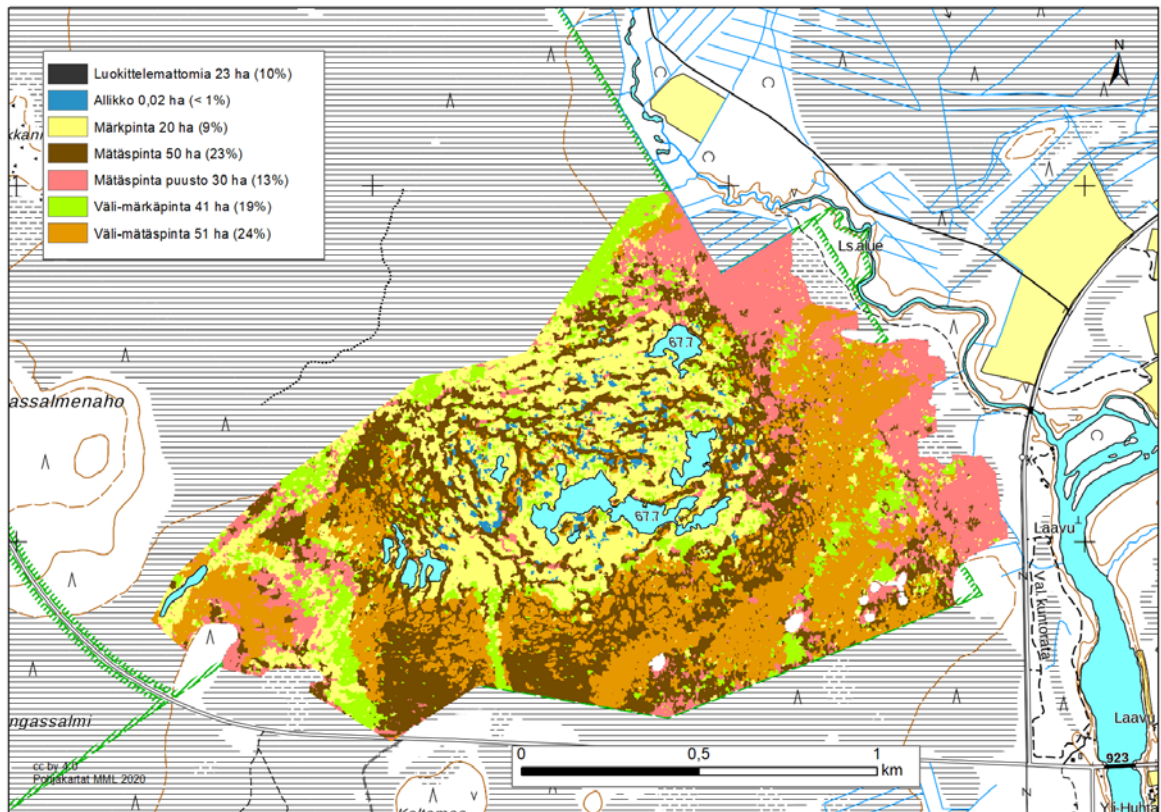
Talulukko 7. Mikrotopografian mukaan luokitellut tasot keidassuolla

Mätäspinta	Väli-mätäspinta	Märkäpinta	Väli-märkäpinta	Mätäspintapuusto	Allikko
50 ha (23%)	51ha (24%)	20 ha (9%)	41 ha (19%)	30 ha (13%)	0,02 ha (<1 %)

Simoskanaavan keidassuoalueen luokittelu kuuteen mikrotopografiseen luokkaan onnistui 84,1% luotettavuudella, mitä voidaan pitää erinomaisena tuloksena. Mätäspinnalla ja märkäpinnalla oli vähiten väärin luokitettuja luokkia. Kummankin luokan todennäköisyydet sille, että niiden luokat on luokiteltu oikein tai niiden arvot ovat oikeassa luokassa oli tuottajan näkökulmasta hieman yli 90% luokitelluista pikseleistä. Välipinta-mätäspinta luokitui myös hyvin, sillä 81% pikseleistä oli oikeassa luokassa. Käyttäjän näkökulmasta katsottuna märkäpinta luokitui parhaiten, 95% pikseleistä oli luokiteltu oikein. Mätäspinta- ja välipinta-mätäspintaluokkien pikseleistä oli käyttäjän näkökulmasta luokiteltuneet 62% ja 64% oikein. Taulukossa 8 on esitetty luokittelun onnistuminen keidassuulla.

Taulukko 8 Keidassuon virhematriisi tuottajan ja käyttäjän luokittelun onnistuminen pikseleineen

Luokka	Tuottajan luotettavuus %	Käyttäjän luotettavuus %	Tuottajan luotettavuus. Pikselit	Käyttäjän luotettavuus. Pikselit
matäspinta	97.81	62.03	312/319	312/503
väli_mätäspin	81.86	64.47	537/656	537/833
märkäpinta	94.45	95.65	4135/4378	4135/4323
allikko	12.92	71.43	35/271	35/49
väli_märkäpin	35.78	29.40	122/341	122/415
mätäspinta_puusto	31.67	92.68	76/240	76/82



Kuva 10. Simoskanaavan keidassuoalueen mikrotopografinen luokitustulos.

## 5.2 Aapasuon luokittelu

Aapasoiden mikrotopografisten luokkien kokonaistarkkuudeksi laskettiin 76,3 % ja kappa-arvoksi 0,650. (Liite 2)

Taulukko 9. Tuottajan ja käyttäjän luotettavuudet keidassoiden luokittelulle viidessä mikrotopografisessa luokassa.

	Mätäspinta	Väli-mätäspinta	Märkäpinta	Väli-märkäpinta	Mätäspinta-puusto
Tuottajan tarkkuus	80,77	82,76	87,62	0,00	19,37
Käyttäjän tarkkuus	85,52	31,69	97,07	0,00	84,55

Luokittelussa olleen aapasuon pinta-ala oli 741 hehtaaria. Kaikkiaan polygoneja muodostui 11618 kappaletta. Märkäpintaa eli rimpitasoa luokittui kolmannes eli 216 hehtaaria. Välipinta-mätäspintatasoa oli hieman vajaa puolet eli 346 hehtaaria. Ulosmaskattujen segmettien osuus oli 3% eli 25 hehtaaria. Mätäspintasoita oli 12% eli 90 hehtaaria ja väli-märkäpintaa oli vajaa vii prosenttia eli 33 hehtaaria. Kuvassa 11 esitetään mikrotopografisten luokkien luokittelutulos Simoskanaavan aapasuoalueella ja liitteessä 3 esitetään kuva aapasuon testialueiden valinnasta.

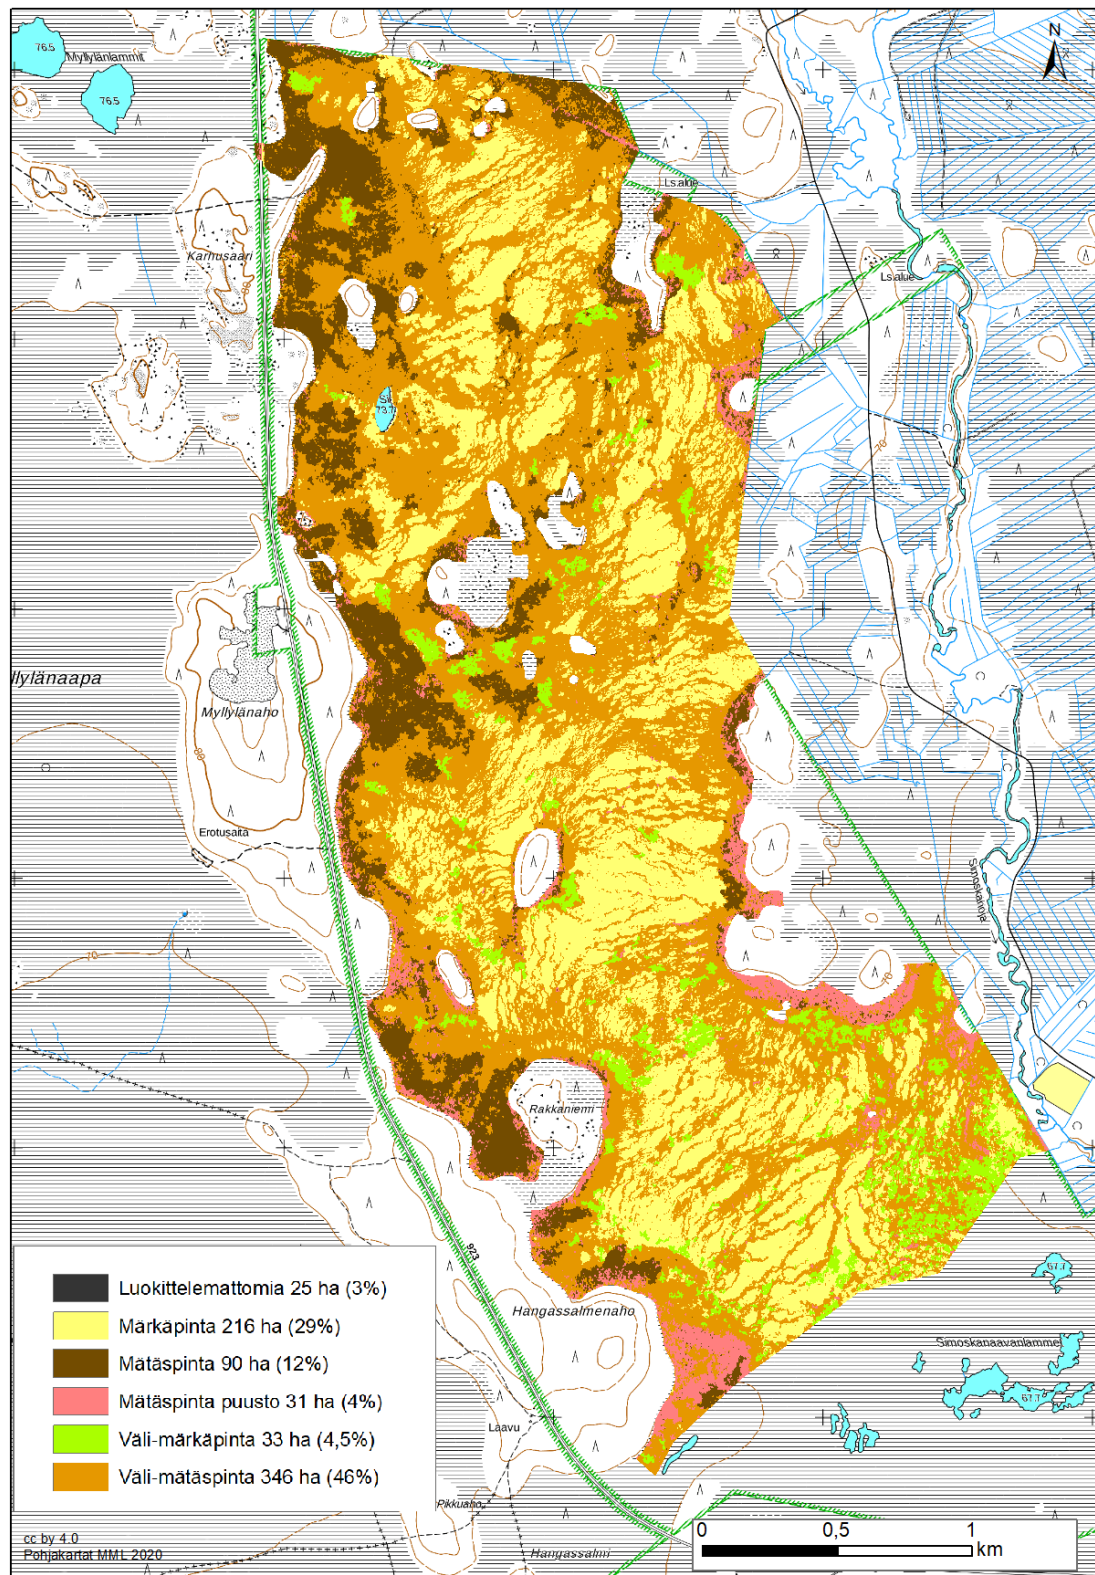
Taulukko 10. Mikrotopografian mukaan luokitellut tasot aapasuolla

Mätäspinta	Välipinta-mätäspinta	Märkäpintaa	Väli-märkäpinta	Mätäspintapuusto
90 ha (12%)	346 ha (46%)	215 ha (29%)	33 ha 84,6%)	31 ha (4%)

Aapasuoalueen luokittelu viiteen mikrotopografisen luokkaan onnistui 76,3% luotettavuudella mikä on hyvä tulos. Tuottajan näkökulmasta mätäspinta, väli-mätäspinta ja märkäpinta luokittuivat 80-87% tarkkuudella ja käyttäjän näkökulmasta mätäspintapuusto, mätäspinta ja märkäpinta luokittuivat hyvin luokittelun onnistuessa 84%-97% luotettavuudella. Taulukossa 9 on esitetty luokittelun onnistuminen aapasuolla.

Taulukko 11. Aapasuon luokittelun virhematriisi.

Luokka	Tuottajan luotettavuus %	Käyttäjän luotettavuus %	Tuottajan luotettavuus. Pikselit	Käyttäjän luotettavuus. Pikselit
mätäspinta	80.77	85.52	13130/16257	13130/15353
väli_mätaspin	82.76	31.69	2294/2772	2294/7240
märkäpinta	87.62	97.07	14123/16119	14123/14550
väli_märkapin	0.00	0.00	0/804	0/1663
mätäspinta_puusto	19.37	84.55	717/3702	717/848



Kuva 11. Simoskanaavan aapasuoalueen mikrotopografinen luokitus.

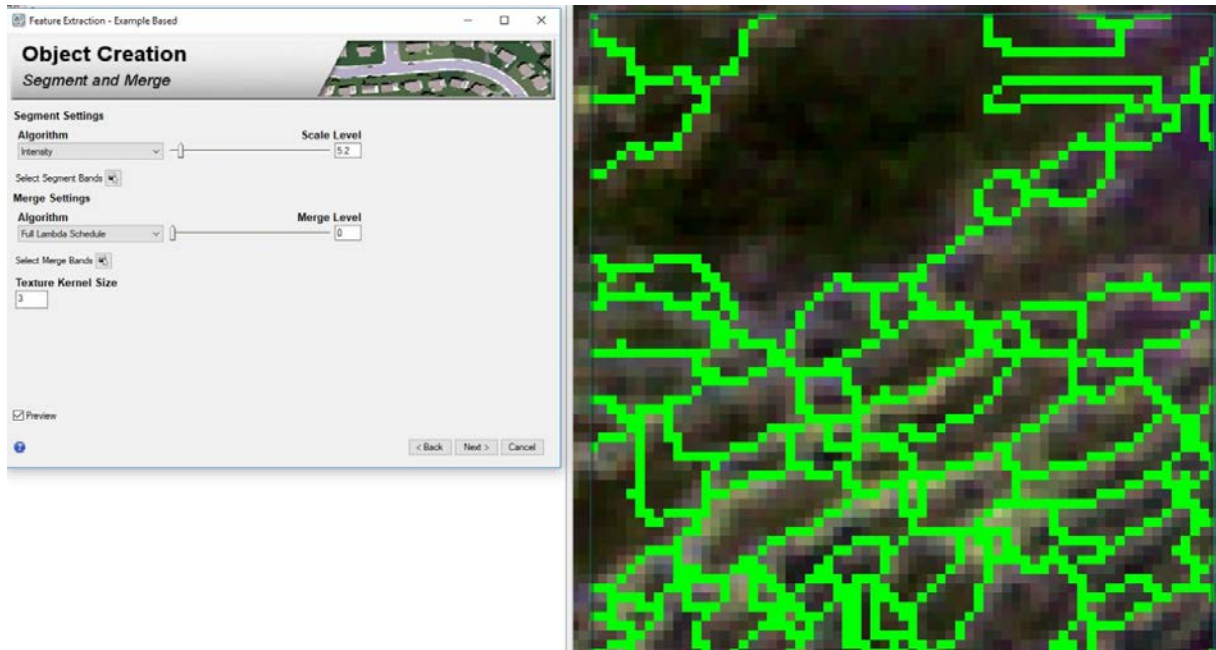
## 6. TULOSTEN TARKASTELU

### 6.1 Luokittelun luotettavuus

Tuottajan näkökulmasta keidassuon luokista välipinta-märkäpinta, mätäspintapuusto ja sekä allikko luokittui heikoiten. Mätäspintapuustoa todennäköisesti luokittui mätäspintaluokkaan enemmän. Allikot ja välipinta-märkäpinnat saattoivat sekoittua keskenään. Ilmakuvissa ja satelliittikuvassa nähdään allikon pinnalla kasvillisuutta. Vesi absorboi säteilyä, joka saa aikaan sen, että kumpikin luokka voi näyttää samalta (Valta- Hulkkonen et. al 2003). Yhtenä selityksenä voisi olla se, että toinen luokista oli luokiteltu väärin joko alkuperäisessä opetusaineistossa tai vertailuluokittelussa.

Väli-märkäpinta luokittui sekä käyttäjän että tuottajan näkökulmasta erittäin huonosti. Luokittelumatriisin mukaan 87% välimärkäpinnasta luokittui märkäpintaan (Liite 2). Pellikan (1997) tutkimuksessa heti kasvillisuuden alla oleva vesi häytti luokittamista, mikä oli todennäköisesti syynä myös tässä. Käyttäjän näkökulmasta väli-mätäspintaan luokittui vain 31,7% pikseleistä. Välipinta luokituu kuivemmassa päässä mätäspintaan ja kosteuden lisääntyessä se liudentuu märkäpinnaksi. Väli-mätäspinta-tasolla on todennäköisesti käynyt näin. Tuottajan näkökulmasta mätäspintapuustoksi ennustetaan 19,37%. Mätäspintapuusto ja mätäspinta ovat todennäköisemmin luokittuneet päällekkäin, eli sekoittuneet keskenään





Kuva 12. Scale – ja Merge funktioiden vaikutus segmentointiin.

Segmentointi tehtiin silmävaraisesti. Tarkoituksena oli aluksi luokitella jänneet ja kermi omaksi luokakseen. Keidassuon rahkaiset pitkänomaiset mätäspintaiset kermi sekoittuivat rahkaisiin pieniin tai laaja-alaisiin mätäspintoihin. Kummassakin vallitsee kasvustona ruskea rahkasammal (*Spagnum fuscum*), jota spektraalisten piirteidesä takia ei pysty erottamaan (Taulukko 8). Kuivat mätäspinnat tai kermi eivät eroa toisistaan kuin muotonsa vuoksi. Kermi ovat pitkänomaisia rahkasammalmättäitä, mitä rahkamättäät eivät ole.

Taulukko 12. Spektraalisten arvojen vaihtelu eri kanavilla.

Rahkaisuus	Sininen (B1)	Vihreä (B2)	Punainen (B3)	NIR (B4)
Kermi	171	204	93	500
Rahkamätäs	182	214	103	362


Viidestä eri kohdasta kermeiltä ja rahkamättäiltä otetut pikseleiden arvot vaihtelivat maltillisesti näkyvän valon aallonpituusalueella. NIR-kanavalla oli enemmän vaihtelua (362-700), joka todennäköisesti johtui rahkamättäillä olevasta puustosta tai kasvillisuudesta

Korkeana ja paikoin leveämpinä olevat keidassuon kermi segmentoituivat hyvin. Tähän saattaa vaikuttaa luokittelussa käytetty Edge-funktio, jolle on ominaista hakea jyrkkärajaisia reunoja. Keidassuon kermijänneet kohoavat suomaastosta ollen selvästi ympäröivää mikrotopografiaa korkeampia, mikä segmentoinnissa huomioitiin spatiaalisesti jyrkkänä TPI-arvojen gradienttina. Segmentoinnissa märkäpintaiset kuljut sekoittuivat allikoihin tai sellaisiin paikkoihin, missä oli pintavettä. Varsinaisessa luokittelussa keidassuon märkäpinta

luokittui erinomaisesti. Leveämmät kermi luokittuivat helposti, mutta myös kapeammatkin segmentoituivat kohtalaisen helposti. Välipinta-märkäpinta yhdistelmä luokittui huonoimmin keidassuolla ehkä luokittelun liian yleistävyyden takia.

Ensimmäisissä luokittelukokeiluissa märkäpinta luokittui allikoiksi tai pieniksi lammiksi tai päinvastoin. Vesi absorboi voimakkaasti ja sen tunnusomaiset spektriset ominaisuudet luokittelussa tulevat lävitse. Lisäksi kasvillisuutta saattaa olla pohjalla tai kellumassa pinnalla, jolloin luokittelu vaikeutuu spektrien samankaltaisuuden vuoksi. Sen sijaan märkäpinta ja kuivat, korkeat ruskorahkasammalmättäät tai ruskorahkasammalkermit toimivat kontrastina toisilleen.

Välipintakasvillisuuden erottaa mätäspinoista mätäspintojen ruskorahkasammaleen puuttumisesta tai ainakin sen huomattavasta vähydestä. Piensaraisuus vallitse toisenlaisten rahkasammalten kanssa, mikä saattaa näyttää vaalealta ilmakuvissa. Suursarat eli yli puolimetriä kasvavat sarat ovat myös yksi välipinnan indikaattori, jotka voivat kasvaa myös rimpinevoilla ja -letoilla väli- ja mätäspinoilla. Suursaraisuus näkyy vääräväri-ilmakuvissa turkoosin ja vihreän sävyisinä. Suon laiteilla saattaa olla piensaraisuutta, mikä vaihtuu suursaraisuudeksi ennen kuin muuttuu lopulta märkäpinnaksi. Keidassuon eteläosassa on yksi tällainen kohde. Luokittelun esikatseluikkunassa ei heti näkynyt segmentointia suursaraisuuden osalta vaan se hakeutui piensaraisuuden kanssa samaan luokkaan kuivemmassa päässä ja märemmässä luokaksi tuli märkäpinta.





Kuva 14. Keidassuon lampien ja kuljujen mosaiikkia WorldView-2 kuvassa. Kuva on otettu 22 heinäkuuta 2016.


Välipinta ja märkäpinnan erotettavuus voi vaihdella. Pohjaveden ollessa koholla välipinta voi luokitella märkäpintaan ja päin vastoin. Jänteillä ja kermeillä välipinta voi olla kapeana suikaleena mätäspinnan ja välipinnan välillä, jolloin sitä ei voi saada kaukokartoitusaineiston luokittelussa. Korkeat välipinnat olivat tehokkaimpia hiilidioksidin nieluja, mutta matalat välipinnat olivat hiilidioksidin lähde (Salli 2015). Mätäspintojen ja rimpipintojen lisäksi välipintojen havaitseminen olisi erityisen tärkeää.

Salli (2015) havaitsi, että hiilidioksidi varastoitui kuivien pintojen kasvillisuuteen tehokkaammin kuin märkien pintojen kasvillisuuteen. Keidassuon rakkaiset kermat ja mättäät, isovarpuiset rämeet suon laiteilla sekä välipintaisten piensaraista kasvillisuutta edustavat suotyypit ovat juuri tämän kaltaisia pintoja.

Aapasualueella ei toiminut keidassuon alalla tehty luokittelu. Soiden rakenne poikkeaa mikrotopografialtaan toisistaan. Aapasuolla jänteillä kasvavat pensaat tai koivuryhmät luokittuivat mätäspintapuustoon. Klorofylli ja biomassa toimivat luokittelussa ratkaisevana tekijänä. Aapasuon luokittelussa voisi käytettiin segmentoinnissa Edge-toimintoa, mutta intensiteetin käyttäminen tasaisella alueella voisi olla perusteltua.

Aapasuolle ovat tunnusomaisia matalat mätäspinta-välipinta-märkäpinnat. Rimpien jänteet eivät kohoa paljoa mikrotopografiasta. Aapasuolla jänteiden luokittelu ei paikoin onnistunut, mutta kokonaisuutena kylläkin. Vaikka segmentointi oli pienipiirteistä, sekoittuivat märkäpinnan ja jänteiden luokat keskenään. Näin tapahtui varsinkin aapasuon keskiosassa. Mahdollisten opetusalueiden useampi sijoittelu tällaiseen pienipiirteiseen, pikselin kokoluokkaa olevien mikrotopografian kohteisiin, saattaisi parantaa mahdollisuutta luokittelun onnistumiseen. Ehkä merkittävin syy luokittelun häilyvyyteen on myös se, että vaihtelu pikselitasolla on niin pienipiirteistä, että se jää näkymättömäksi. Kohteet ovat alttiita luokittelussa sekapikselleille. Tämä johtunee siitä, että objektipohjaisessa luokittelussa käytetty funktio perustuu watershed-funktioon, mikä voi paikoin olla epäsovelias. Hyvällä segmentointi-algoritmillä voisi olla mahdollisuuksia tunnistaa paremmin myös kohteen muotoja. Tämä olisi tärkeää varsinkin pitkänomaisten jänteiden ja märkäpintojen erottelussa keskenään. Jänteiden ja kermien erotteluun voisi tehdä jatkossa erikseen ottamalla

opetusalueiksi vain niitä, eikä oteta kantaa, onko niissä pensaita tai puustoa. Toinen vaihtoehto olisi, että maskataan puustoiset osat pois.



Kuva 15. Aapasuon luokiteltujen jänteiden erottuminen ilmakuvasta. (Ilmakuva Maanmittauslaitos, avoimien aineistot, cc by 4.0 lisenssi)

## 6.2 Merkitys hiilivarastona

On olemassa malleja luonnontilaisten soiden hiilen kierrosta. Korkea pohjaveden korkeus aiheutti Almin tutkimuksessa (1997), että hiilen kertymä oli suurinta rimmillä, tupasvillavälipinnoilla ja saravälipinnoilla ja alhaisin mätäspintaissa pienillä mikrokoealueilla (2.91, 6.08, 2.83 and 2.66 mol C m<sup>-2</sup>, vastaavasti). Vastaavasti Alm et al. (1997) totesivat, että koko tutkimusalueensa turvealueella hiilen kertymä oli 5.66 mol m<sup>-2</sup> year<sup>-1</sup>. Keskikiesällä, kun alkutuotanto on suurimmillaan, mätäspinnat matalan pohjaveden aikaan luovuttivat vähemmän metaania kuin normaalin nettohiilenvaihdon (NEE) mukaan oli ennustettu, kun taas saravälipinnat vapauttivat hieman enemmän. Vuotuinen hiilen kertyminen ei korreloinut vuotuisen metaanipäästön kanssa Almin tutkimuksessa. Koko yhteisön hiilidioksidipäästö pienellä koealalla näytti olevan suhteessa metaanipäästöön märät mikrokoealat mukaan lukien. Päivittäinen tasapaino hiilen kertymisessä on epävakaa ja

sääriippuvaista ja voi vaihtua hiilen nettositoutumisesta nettopäästöön lämpimimmässä ja kuivemmissa olosuhteissa ensisijaisesti avosoiden korkeilla mättäillä. (Alm et al. 1997)

Länsi-Siperian soiden pitkän ajan hiilen kertymissuhde (LORCA) kolmen suotyypin osalta ei poikennut merkittävästi toisistaan ollen  $17,2 \pm 1,0$  (SE)  $\text{g m}^{-2} \text{yr}^{-1}$ . Tutkimuksessa suotyyppeinä olivat keidasräme, isovarpuräme ja rahkaräme. Samassa tutkimuksessa arvoitiin nykyisestä hiilestä 55% kertyneen suohon 6000 BP (Turunen et al. 2001).

Suon mikrotopografian tunteminen auttaa soiden hiilitaseen tutkimuksessa. Keskiravinteisella Metsä-Lapin aapasuolla Kaamasessa tehdyssä tutkimuksessa varvuttomat jänteet olivat yleensä hiilidioksidin nettolähteitä myös keskellä voimakkainta kasvukautta. Hiilidioksidin lähteinä olivat jänteet, joilla kasvoi variksenmarjaa ja hillaa. Sen sijaan välipinnat, rimpipinnat ja jänteet, joilla kasvoi varpuja, olivat päivisin nettositojia. Pohjaveden pinnan eron vuoksi yhteyttäminen ja soluhengitys oli kaksi kertaa suurempi välipinnoilla kuin rimmillä. Alueilla, joissa pohjaveden pinta oli vakaa ja korkea, hiilen kiertonopeus oli hidas. (Heikkinen 2002)

Sepän tekemässä tutkimuksessa (1996) todettiin jänteiden reunojen olevan jyrkempiä kuin mättäiden reunojen. Ruuhijärven (1982) tekemässä tutkimuksessa todettiin, että kevättulva ehkäisee rahkasammaleiden tulemista hallitseviksi. (Heikkinen 2002). Lyhyt kasvukausi yhdessä edellä mainittujen syiden takia kerryttää hiilen kertymistä märkiin rimpiin ja kosteisiin välipintoihin. (Heikkinen 2002)

Märillä rimmillä esiintyy suurta ajallista ja spatiaalista vaihtelua metaanipäästöissä Heikkisen (2002) mukaan. Bubier et al. (1995) mukaan pohjaveden pinnan korkeus korreloi metaanipäästöjen kanssa. Korkeimmat metaanipäästöt olivat keidassoilla ja nevan vesialtailla, missä tapahtui turpeen maatumista. Sarat ja lierosammalet olivat parhaita indikaattoreita arvioitaessa pohjaveden määrää ja hiilidioksidi -ja metaanipäästöjä.

Tässä tutkimuskohteena olevat aapasuon jänteet ovat määritelmän mukaan pitkänomaisia välipintaista tai mätäspintaista nevaa, lettoa tai rämettä. Tarkemmilla kaukokartoituskuville voi havaita esimerkiksi vesiherne ja lierosammalkasvustoja ja siten voidaan määrittää trofiatasot.

Laserkeilausaineistoaineiston ja siitä laskettujen TPI ja TDR- mallien avulla voitiin mallittaa suon pintaa hyvin, mutta näiden tieto hävisi tässä tutkimuksessa muualle tai sitä ei osattu käyttää oikein aiheuttam orldView-2-kuvat yhdessä NDVI-kasvillisuusindeksin kanssa antoivat kaiken kaikkiaan hyvän tuloksen keidassuon luokituksessa ja ominaisuuksien kartoituksessa. Aapasuo-osalla pitää pohtia luokittelun onnistumista. MML:n ilmakuvien käyttö luokituksen apuna on toimiva.

### 6.3 Hiilitase

Luonnontilaisten soiden kasvihuonekaasujen vaihtoon vaikuttavat sää-, ja ilmasto-olot. Lämpiminä ja kuivina kesinä pohjaveden pinta voi laskea, jolloin paljastuessa turvekerroksessa kuolleen kasviaineksen hajotus nopeutuu ja hiiltä vapautuu enemmän (Alm et al 1997; Heikkinen et al 2002). Tällöin suosta voi tulla nettopäästäjä. Kun tarkempia tutkimustietoja saadaan enemmän eri suotyyppien ja pientasotopografisten piirteiden ominaisuuksista kasvihuonekaasujen lähteinä tai nieluina, myös luonnontilaisten soiden hiilitaseet voidaan tulla huomioimaan kansainvälisessä kasvihuonekaasujen inventoinnissa.

Suomen soiden kokonaishiilitaseiden laskemista varten suotyyppien ja mikrotopografisten piirteiden kartoittaminen on tulevaisuudessa tärkeää. Soiden kasvihuonekaasutaselaskelmissa käytettävät päästökertoimet riippuvat suokuvion ravinteisuustasosta, jotka voidaan yleistää suotyypeistä (Turunen et al. 2002), ja suon hydrologisesta tilasta eli pohjavesipinnan korkeudesta (Minkkinen et al. 2007). Kasvihuonekaasutaselaskelmien keskeinen pohjatieto on kuviokohtainen paikkatieto suotyypeistä ja niiden ravinteisuustasoista.

Tutkimusalueella näkyy sekä pohjakartoissa että MML:n ilmakuvissa muutama kulju tai rimpisuolla pieniä lätäköitä. Sen sijaan WorldView-2-kuvassa niitä ei näy tai ne on maskattu pois. Simoskanaapa on luonnontilainen suo, jossa ei siis ole ojia ja niiden välitöntä kuivatusvaikutusta Alm et al. (1997), Heikkinen et al. (2002) Turunen et al (2002). Tutkimuksista voi päätellä, että Simoskanaavan keidassuo voi olla nettositomisen sijaan nettopäästäjä lämpiminä ja kuivana kesänä, erityisesti avosoiden korkeilla mättäillä.

Kuivana ja lämpimänä kesänä aapasuon jänteet ovat usein metaanin sitojia koko kasvukauden ajan. Kasvukauden alussa rimpien metaanipäästöt olivat suurempia kuin välipintojen, mutta myöhemmin kasvukautena ei ollut eroa päästöissä. Tähän lienee ollut syynä lyhytkortisten kasvien kasvu kesän aikana. Suurin vaihtelu metaanipäästöissä oli mikropinnoilla, joilla

pohjaveden pinta oli yli tai lähellä turpeen pintaa. Nämä olivat siis rimpi- ja välipinnoilla. Hiilitasetta (sähköpostikeskustelu Toivonen, J ja Rauhala J, 4.12.2020) tulisi mikropinnoilta kuten myös rimpi-jänne-tasolta aluksi laskea vain karkealla luokittelulla. Tämän jälkeen voi soveltaa luokiteltuihin mikropintoihin sitten niitä edustavia hiilikertymiä, josta saadaan kokonaistase. Tulosta verratessa laskelmiin, joissa käytetään vain yhtä hiilenkertymäarvoa voidaan nähdä ero hiilikertymissä. Karkeasti yleistettynä Simoskanaavan keidassuon pitkän ajan hiilen kertymissuhde hiilen varastoitumisessa (LORCA) olisi  $26,1 \text{ g m}^{-2} \text{ yr}^{-1}$  ja aapasuolla  $17,3 \text{ g m}^{-2} \text{ yr}^{-1}$ .

## 6.4 Virhelähteet

Referenssipikseleiden määrän on katsottu olevan merkittävässä asemassa tilastollisesti merkittävän luotettavuudenmäärittämisen suhteen. Luokituksen luotettavuuden määrittämisen  $\pm 5$  prosentin tarkkuudella vaatisi vähintään 250 referenssipikselin otantaa (Congalton 1991). Tämän mukaan tutkimuksen tulokset ovat tilastollisesti merkittäviä.

Yksittäinen virhelähde on luokittelijan oletus kuvalta tietyn näköisestä kasvillisuudesta ilman tutkimuskohteella käyntiä; tällöin opetusalueet ovat lähtökohtaisesti väärin. Harha voi kertaantua valittaessa testialueita, jolloin valitaan myös väärän luokkaan kuluvia alueita. Syntyneet luokat saattavat silti olla oikein segmentoituneita, mutta luokan nimi voi olla todellisuudessa eri.

## 6.5 Jatkotutkimukset

Korkean resoluution satelliittikuvan ja laserkeilausaineistosta johdettuja korkeuteen ja pinnanmuotoihin liittyviin tasoihin on tehokas aineistoyhdistelmä soiden kasvillisuusluokittelussa. Jatkotutkimuksen kannalta voisi pohtia karkeaa suotyyppeihin menevä luokittelua, josta voisi jatkaa objektiperusteista kuvankäsittelyä hyödyntäen tarkempaan luokitteluun. Tutkimus voisi olla kaksivaiheinen, jossa ensimmäisessä vaiheessa käytetään apuna ilmaisaineistona esimerkiksi keskitasen resoluutiolla olevia satelliittikuvia ja toisessa vaiheessa valitaan tietty alue korkean resoluution satelliittikuvalta esimerkiksi SAR-satelliittikuvalta tehtävään luokitteluun. Tutkimuksessa voisi käyttää Maanmittauslaitoksen uutta ja tarkempaa laserkeilausaineistoa. Tutkimusalueen voi luokitella suotyyppeihin, joille

voi laskea päästökertoimia hyväksi käyttäen suon hiilitaseet. Tutkimuksessa pitää käyttää maastossa tehtyä referenssiaineiston luokittelutiedon keruuta sekä opetusalueiden valinnassa että lopullisessa luokittelun oikeellisuuden tarkastuksessa mahdollisten korjausten tekemiseksi tai luokitteluvirheiden ymmärtämiseksi.

## 7. YHTEENVETO

Kaukokartoitusmenetelmät käyttäen korkean resoluution optista satelliittikuvaa ja laserkeilausaineistosta tehtyä korkeusmallia pystyivät erottamaan mätäspinnat, välipinnat ja märkäpinnat. Keidassuolla kuin myös aapasuolla tämä onnistui hyvin. Toisena tavoitteena oli tarkastella objektiperusteisen luokittelu- ja tunnistustavan sopivuutta jänteille ja vesipinnoille korkean resoluution spatiaalisista aineistoista. Luokittelu onnistui hyvin sekä keidassuon että aapasuon osalta. Luokkien sekoittumista tapahtui välipinta-märkäpintatasoilla, joissa veden signatuuri hallitsee. Luokittelusta voi tehdä karkean mallin hiilitaseesta käyttämällä koko suolle arvioituja taulukkoa hiilen määrän arvioimiseen. Karkeasti yleistettynä Simoskanaavan keidassuon pitkän ajan hiilen kertymissuhde hiilen varastoitumisessa (LORCA) olisi  $26,1 \text{ g m}^{-2} \text{ yr}^{-1}$  ja aapasuolla  $17,3 \text{ g m}^{-2} \text{ yr}^{-1}$

## 8. KIITOKSET

Erityiset kiitokset ohjaajilleni Geologian tutkimuskeskuksen apulaistutkimusprofessori Maarit Middletonille ja Helsingin yliopiston geotieteiden ja maantieteen osaston professori Petri Pellikalle. Kiitos myös Geologian tutkimuskeskuksen erikoistutkijalle Jukka Turuselle ja tutkijoille Janne Kivilompololle ja Eija Hyvöselle sekä assistentti Viena Arvolalle.

Kiitokset kuuluvat myös Helsingin yliopiston opetus- ja opiskelupalvelun koulutussuunnittelijalle FT Katariina Kososelle, jonka ansiosta loppu aikataulut pitivät.

## 9. LÄHTEET

Alm, J., L., Schulman, J., Walden, H., Nykänen, P. J., Martikainen, J., Silvola, 1999. Carbon balance of a boreal bog during a year with an exceptionally dry summer, *Ecology* 80 (1), pp. 161-174. [viitattu 2.11.2020]. Saatavissa

<https://esajournals.onlinelibrary.wiley.com/doi/epdf/10.1890/0012-9658%281999%29080%5B0161%3ACBOABB%5D2.0.CO%3B2>

Arkimaa, H., Middleton, M., Hyvönen, E., Kuosmanen, V., Laitinen, J., & Sutinen, R. (2005). Mire site type mapping of boreal peatlands with hyperspectral airborne HyMap in northern Finland. In B. Zagajewski, M. Sobzak, & M. Wrzesien (Eds.), 4th workshop on imaging spectroscopy. New quality in environmental studies (pp. 329–336).

Axelsson, P., 2000. DEM generation from laser scanner data using adaptive TIN models, in: Dieter Fritsch, D., Molenaar, M. (Eds.), XIXth ISPRS Congress, Technical Commission IV: Mapping and Geographic Information Systems, July 16–23, 2000, Amsterdam, The Netherlands, International Archives of Photogrammetry and Remote Sensing XXXIII (B4), 110–117.

Aurela, M., Lohila, A., Tuovinen, J-P. Hatakka, J., Riutta, T., Laurila, T. 2009. Carbondioxide Exchange on a Northern Boreal Fen. *Boreal Environment research* 14, pp. 699-710

Aurela, M., Laurila, T., Tuovinen, J-P. 2001. Seasonal  $CO_2$  Balances of Subarctic Mire. *Journal of geophysical research*, 106, (2), pp. 1623-1637

Baaz, M., Hoffmann, G., Willhauck, G. 2008. Progressing from object-based to object-oriented image analysis. *Object -Based Image Analysis*. **PP**. 29-42

Bourgeau-Chavez, L.L., Endes, S.L., Graham, J.A., Hribljan, J.A.; Chimner, R.A.; Lillieskov, E.A., Battaglian, M.J. 2018. 6.04—Mapping Peatlands in Boreal and Tropical Ecoregions. In Comprehensive Remote Sensing; Liang, S., Ed.; Elsevier: Oxford, UK, 2018; pp. 24–44.

Bourgeau-Chavez, L. L., Endres, S., Powell, R., Battaglia, M. J., Benscoter, B., Turetsky, M., Kasischke, E. S., & Banda, E. (2017). Mapping boreal peatland ecosystem types from multi-temporal radar and optical satellite imagery. *Canadian Journal of Forest Research*, 47(4), 545–559. <http://dx.doi.org/10.1139/cjfr-2016-0192>.

Bubier, J.S. 1995 The Relationship of Vegetation to Methane Emission and Hydrochemical Gradients in Northern Peatlands. *Journal of Ecology* 83 pp. 403-420 [VIITATTU 12.11.2020] Saatavissa. <https://www.mtholyoke.edu/courses/jbubier/pdf/Bubier95JE83.PDF>

Chavez, P.S. 1996. Image Based Atmospheric Corrections-Revisited and Improved. *Photogrammetric Engineering & Remote Sensing* 62 (9). pp. 1025-1036

M., Malmer, N., Friborg, T., Crill, P., And Svensson, B.H..2004.Thawing sub-arctic permafrost: Effects on vegetation and methane emissions, *Geophysical Research Letters*. 31, L04501. [viitattu 1.10.2020] Saatavissa <https://www.forskningsdatabasen.dk/en/catalog/2397972613>

Clymo, R. 1983. Peat, in: *Ecosystems of the world*, vol. 4A, Mires: swamp, bog, fen and moor, edited by: Gore, A. J. P., Elsevier, Amsterdam. pp. 159–224 [viitattu 20.10.2020]. Saatavissa <http://research.sbc.sqmul.ac.uk/r.clymo/Clymo-full-list-publications.html>

Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment* 37 (1), 35-46.



Daulaut, W., E. , Clymo, R., S. 1998. Effects Of Temperature And Watertable On The Efflux of Methane from Peatlands Surface Core. *Atmospheric Environment*. 32 (19), pp. 3207-3218

Deering, D.W., Haas, R.H 1980. Using Landsat Digital Data for Estimatin Green Biomass. NASA Goddard Space Flight Center. Greenbelt, Md 20771. Report No TM80727. [viitattu 1.12.2020] Saatavissa  
<https://ntrs.nasa.gov/api/citations/19800024311/downloads/19800024311.pdf>

Dechka, J.A., Franklin, S.E., Watmough, M.D., Bennett, R.P. & Ingstrup, D.W. 2002. Classification of wetland habitat and vegetation communities using multi-temporal Ikonos imagery in southern Saskatchewan. *Canadian Journal of Remote Sensing* 28 (5), 679-685.

Dissanska, M., Bernier, M. & Payette, S. 2009. Object-based classification of very high resolution panchromatic images for evaluating recent change in the structure of patterned peatlands. *Canadian Journal of Remote Sensing* 35, 189-215. <https://doi.org/10.5589/m09-002>

Esa Sentinel Online. Satellite Description. [verkkoaineisto]. [viitattu 27.8.2020]. Saatavissa  
<https://earth.esa.int/web/sentinel/missions/sentinel-2/satellite-description>

ESA 2020. [verkkoaineisto]. [viitattu 27.8.2020]. Saatavissa  
<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial>

ESA 2020. [verkkoaineisto]. [viitattu 27.8.2020]. Saatavissa  
<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions/radiometric>

Eurola, S., Huttunen A., Kukko-Oja, K. 1994. Suokasvillisuusopas. Oulanka Reports 13, p.81

Grenier, M., Demers, A., Labrecque, S., Benoit, M., Fournier, R. A., & Drolet, B. (2007). An object-based method to map wetland using RADARSAT-1 and Landsat ETM images: Test case on two sites in Quebec, Canada. *Canadian Journal of Remote Sensing*, 33, 528–545.

Elberling, B., Christiansen, H.H., Hansen, B.U., 2010. High nitrous oxide production from thawing permafrost, *National Geoscience*, 3(5), pp. 332–335

ESA 2020. Third Party Missions overview [viitattu 1.11.2020] Saatavissa [https://www.esa.int/Applications/Observing\\_the\\_Earth/Third\\_Party\\_Missions\\_overview](https://www.esa.int/Applications/Observing_the_Earth/Third_Party_Missions_overview)

ESA 2020b. Sentinel Online. Multi Spectral Instrument (MSI). . [verkkoaineisto].[viitattu 27.8.2020] Saatavissa:[<https://earth.esa.int/web/sentinel/missions/sentinel-2/instrument-payload> doi:10.5194/esd-2-121-2011

Gallant, J.C., Wilson J.P. 2000. Primary topographic attributes. J.P. Wilson, J.C. Gallant (Eds.), *Terrain Analysis: Principles and Applications*, Wiley, New York (2000), pp. 51-85

Geologian Tutkimuskeskus. 2020. [viitattu 1.11.2020] Saatavissa [http://gtkdata.gtk.fi/Turvevarojen\\_tilinpito](http://gtkdata.gtk.fi/Turvevarojen_tilinpito)

Geologian tutkimuskeskus 2020. Maankamara. [viitattu 1.11.2020] Saatavissa <https://gtkdata.gtk.fi/Maankamara/index.html>

Gorham, E., 1991. Northern Peatlands; Role in Carbon Cycle and Probable Response to the Climatic Warming. *Ecological Society of America* 1(2), pp.182-19

HARRIS 2020a. Envi User Guide. Calculate Confusion Matrices.

HARRIS 2020b. Feature Extraction with Example-Based Classification Tutorial.List of attributes.

HARRIS 2020c. Adaptive Filters

Harris, A., & Bryant, R. G. 2009. A multi-scale remote sensing approach for monitoring northern peatland hydrology: Present possibilities and future challenges. *Journal of environmental management*, 90(7), 2178–2188.

Heikkinen, J.E.P., Maljanen, M., Aurela, M., Hargreaves, K.J., Martikainen, P.J. 2002. *Polar Research* 21 (1), pp.49-62

Huang, L.X. & Sheng, G. 2005. Classification of the Lakkasuo Peatland Ecosystem Using Remote Sensing. *Environmental Informatics Archives* 3, 295-305.

Hyvönen, R., Ågren, G.I., Linder, S., Persson, T., Persson, T., Cotrufo, M.F., Ekblad, A., Freeman, M., Grelle, A., Janssens, I.A., Jarvis, P.G., Kellomäki, S., Lindroth, A., Loustau, D., Lundmark, T., Norby, R.J., Oren, R., Pilegaard, K., Ryan, M.G., Sigurdsson, B.D., Strömgren, M., Van Oijen, M., Wallin, G. 2007. The Likely Impact of Elevated ( $CO_2$ ) Nitrogen Deposition, Increased Temperature, and Management on Carbon Sequestration in Temperate and Boreal Forest Ecosystems: a literature Review. *New Phytologist* 173. pp.463-480 [viitattu 1.11.2020.]. Saatavissa [https://www.researchgate.net/publication/235331832\\_The\\_likely\\_impact\\_of\\_elevated\\_CO2\\_nitrogen\\_deposition\\_increased\\_temperature\\_and\\_management\\_on\\_carbon\\_sequestration\\_in\\_temperate\\_and\\_boreal\\_forest\\_ecosystems\\_A\\_literature\\_review](https://www.researchgate.net/publication/235331832_The_likely_impact_of_elevated_CO2_nitrogen_deposition_increased_temperature_and_management_on_carbon_sequestration_in_temperate_and_boreal_forest_ecosystems_A_literature_review)

Härkönen, E., Paalamo, P., Rautiainen, P., Tuovinen, E. 2010 Martimoaapa–Lumiaaapa–Penikat Natura 2000 -alueen hoito- ja käyttösuunnitelma. Metsähallituksen luonnonsuojelujulkaisusarja. C71. Metsähallitus 2010

Ilmatieteenlaitos 2020. [Viitattu 25.10.2020] Saatavissa <https://www.ilmatieteenlaitos.fi/terminen-kasvukausi>

International Peatland Society. [viitattu 1.9.2020] Saatavissa 2020. <https://peatlands.org/peatlands/mire-classification-and-typology/>

IPCC, 2018. Special Report: Global Warming of 1,5° C [viitattu 1.9.2020] Saatavissa <https://www.ipcc.ch/sr15/chapter/spm/>.

IPCC, 2013: *Climate Change 2013: The Physical Science Basis*. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp.[viitattu 1.9.2020]. Saatavissa <https://www.ipcc.ch/report/ar5/wg1/>

Jensen, J. R. 1996. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 2d ed. Englewood Cliffs, New Jersey: Prentice-Hall

Jin, X. 2012. Segmentation-based image processing system. U.S. Patent 8,260,048, filed Nov. 14, 2007, and issued Sept. 4, 2012.

Kareinen, J. 2007. Korkeusmallin luonti laserkeilausaineistosta. Maanmittausostato. Teknillinen korkeakoulu. [viitattu 3.12.2020] saatavissa [https://foto.aalto.fi/opetus/270/esitelmat/2007/Kareinen\\_Juha.pdf](https://foto.aalto.fi/opetus/270/esitelmat/2007/Kareinen_Juha.pdf)

Kauppi, P.E., Posch, M., Hänninen, P., Henttonen, H.M., Ihalainen, A., Lappalainen, E., Starr, M. And Tamminen, P. 1997. Carbon reservoirs in peatlands and forests in the boreal regions of Finland. *Silva Fennica* 31(1),pp. 13–25.

Korpela, I., Koskinen, M., Vasander, H., Holopainen, M., Minkinen, K. Airborne small-footprint discrete-return LiDAR data in the assessment of boreal mire surface patterns, vegetation and habitats. *Forest Ecology and Management* 258 (7),1549-1566, 2009. <http://dx.doi.org/10.1016/j.foreco.2009.07.007>

Korpela, I., Haapanen, R., Korrensalo, A., Tuittila, E.-S., Vesala, T. Fine-resolution mapping of microforms on a boreal bog using aerial images and waveform-recording LiDAR. *Mires and Peat*. 2020 <https://doi.org/10.19189/MaP.2018.OMB.388>

Laine J., Vasander, H. 2008. Suotyyppit ja niiden tunnistaminen. Metsäkustannus Oy. Hämeenlinna

Lang, M.W., Bourgea-Chavez, L.L., Tiner, W., Klemas, V.V. 2015. Advances in remotely Sensed Data and Techniques for Wetland Mapping. Remote Sensing of Wetlands. Applications and Advances. CRS Press. Taylor & Francis Group

Limpens, J., Berendse, F., Blodau, C., Canadell, J. G., Greeman, C., Holden, J., Roulet, N., Rydin, H., Schapmann-Strub, G. 2008. Peatlands and the carbon cycle: from local processes to global implications - a synthesis, Biogeosciences, 5, 1475–1491. [viitattu 1.10.2020]  
Saatavissa <https://hal.archives-ouvertes.fr/hal-00297992/document>

Lillesand, T., Kiefer, R.W., Chipman, J. 2015. Remote Sensing and Image Interpretation. John Wiley & Sons, 18.2.2015 - 736 sivua.

Maa- ja metsätalousministeriö 2020. [Viitattu 17.11.2020] Saatavilla <https://mmm.fi/lulucf>

Maanmittauslaitos 2020b. Avoimien aineistojen latauspalvelu. . [viitattu 1.11.2020]  
Saatavissa <https://www.maanmittauslaitos.fi/asioi-verkossa/avoimien-aineistojen-tiedostopalvelu>

Maanmittauslaitos 2020a. Lasekeilausaineisto 2008-2019. [viitattu 1.11.2020] Saatavissa. <https://www.maanmittauslaitos.fi/kartat-ja-paikkatieto/asiantuntevalle-kayttajalle/tuotekuvaukset/lasekeilausaineisto>

Maanmittauslaitos 2020c. Maanmittauslaitoksen ilmakuva. [viitattu 28.11.2020] Saatavissa <https://www.maanmittauslaitos.fi/kartat-ja-paikkatieto/asiantuntevalle-kayttajalle/tuotekuvaukset/ilmakuva>

Metsähallitus 2020. Luontotyypien suojelu. [viitattu 1.11.2020] Saatavissa <https://www.metsa.fi/luonto-ja-kulttuuriperinto/lajien-ja-luontotyyppien-suojelu/luontotyyppien-suojelu/>

Mellilo, J.M., Mcguire, A.D., Kicklighter, D.W., Moore Iii, B., Vorosmarty, C.J., Schloss, A.L. 1993. Global Climate Change and Terrestrial Net Primary Production. *Nature* 363. pp 234-240

Middleton, M., 2014. Hyperspectral Close Range and Remote Sensing of Soils and Related Plant Associations. Spectroscopic-applications in the Boreal Environment. Academic . Dissertation. Geological Survey of Finland. pp. 609.

Middleton, M., Närhi, P., Arkimaa, H., Hyvönen, E., Kuosmanen, V., Treitz, P. & Sutinen, R. 2012. Ordination and hyperspectral remote sensing approach to classify peatland biotopes along soil moisture and fertility gradients. *Remote Sensing of Environment* 124, 596-609. doi:10.1016/j.rse.2012.06.010.

Mikkola, J. Pellikka, P. 2002. Normalization of bi-directional effect in aerial CIR photographs to improve classification accuracy of boreal and subarctic vegetation for pollen landscape calibration. *International Journal of Remote Sensing* 23:21 pp 4719-4742. <https://doi.org/10.1080/01431160110113944>

Miller, H.G., Singh, V., 1994. Potential field tilt - a new concept for location of potential field sources. *J. Appl. Geophys.* 32, 213–217. [https://doi.org/10.1016/0926-9851\(94\)90022-1](https://doi.org/10.1016/0926-9851(94)90022-1).

Minasny, B., Berglund, Ö., Connolly, J., Hedley, C., de Vries, F., Gimona, A., Kempen, B., Kidd, D., Lilja, H., Malone, B., McBratney, A., Roudier, P., O'Rourke, S., José Padarian, R., Poggio, L., ten Caten, A., Thompson, D., Tuve, C., Widyatmanti, W. 2019. Digital mapping of peatlands – A critical review. *Earth-Science Reviews* 196, <https://doi.org/10.1016/j.earscirev.2019.05.014>.

Minkkinen, K., Laine, J., Shurpali, N., Mäkiranta, P., Alm, J. & Penttilä, T. 2007.

Heterotrophic soil respiration in forestry-drained peatlands. *Boreal Env. Res.* 12:115-126.

Moore, P.A., Lukenbach, M.C., Thompson, D.K., Kettridge, N., Granath, G., Waddington, J.M. 2019. Assessing the Peatland Hummock-Hollow Classification Framework Using High-Resolution elevation Models: Implications for Appropriate Complexity Ecosystem Modelling. *Biogeosciences* 16, pp. 3491-3506.. <https://doi.org/10.5194/bg-16-3491-2019>, 2019

Moran, M.S, Bryant, R., Thome, K., Nouvellon, W. Ni., Gonzales- Dugo, M.P., Qi, J., Clarke, T.R. 2001. A refined empirical line approach for reflectance factor retrieval from Landsat-5 TM and Landsat-7 ETM+. *Remote Sensing of Environment* 78, pp. 71-82

Martikainen, P. 1997. Reconstruction of the carbon balance for microsites in a boreal oligotrophic pine fen, Finland. *Oecologia* 110, pp. 423-431

Pellikka, P., 1998. Development of correction chain for multispectral airborne video camera data for natural resource assessment. *Fennia*, 176:1, pp. 1–110.

Pellikka, P. 1997. Stratified classification of digitized aerial photography to avoid misclassification of subarctic vegetation types in northern Finland. *The Photogrammetric Journal of Finland* . 15 (2). pp 21-30

Post, M., Emanuel, W., Zinke, P., Stangenerger, A. 1982. Soil Carbon pools and World Life Zones. *Nature* 298, pp. 156-159

Salli, U. 2015. Keidassuoekosysteemin kasviyhteisötyyppien hiilidioksidin vaihto. Pro gradu-tutkielma. Itä-Suomen yliopisto, Biologian laitos.

Schaaf, C.B., Xiaowen, L., Strahler, A. 1994. Topographic Effects on Bidirectional and Hemispherical Reflectances Calculated with a Geometric\_Optical Canopy Model. *Geoscience and Remote Sensing* 32 (6). pp.1186-1193

Schopfer, J., Dangel, S., Kneubuhler, M., Itten, K. 2008. Sensors 8 (8). pp. 5120-5140.  
[Viitattu 1.10.2020] Saatavissa <https://doi.org/10.3390/s8085120>

Suhet 2013. Approved by Bianca Hoersch. Sentinel-2 User Handbook.  
[verkkoaineisto] Revision 1. ESA Standard Document 24.7.2015 Issue 1 Rev 2, pp. 64  
[viitattu 27.8.2020]. Saatavissa [https://earth.esa.int/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://earth.esa.int/documents/247904/685211/Sentinel-2_User_Handbook)

Suomen kallioperä – DigiKP. Digitaalinen karttatietokanta [Elektroninen aineisto]. Espoo: Geologian tutkimuskeskus [viitattu 5.12.2020]. Versio 2.1.

Suomen ympäristökeskus 2020a. Ladattavat paikkatietoaineistot. [Viitattu 2.10.2020].  
saatavilla. <https://ckan.ymparisto.fi/dataset/%7B16683200-FD86-43F2-A170-357BDF44BA1C%7D>

Suomen ympäristökeskus 2020b. Suot. Luontotyyppien uhanalaisuus. [Viitattu 2.10.2020].  
saatavilla. [https://www.ymparisto.fi/fi-FI/Luonto/Luontotyyppit/Luontotyyppien\\_uhanalaisuus/Suot](https://www.ymparisto.fi/fi-FI/Luonto/Luontotyyppit/Luontotyyppien_uhanalaisuus/Suot)

Tans, P., Fung, I., Takahashi, T., 1990. Observational Constraints on the Global Atmospheric CO<sub>2</sub> Budget. Science 247, pp. 1431-1438  
[https://www.researchgate.net/profile/Taro\\_Takahashi/publication/6049747\\_Observational\\_Constraints\\_on\\_the\\_Global\\_Atmospheric\\_CO2\\_Budget/links/53cfb550cf2fd75bc59e69d.pdf](https://www.researchgate.net/profile/Taro_Takahashi/publication/6049747_Observational_Constraints_on_the_Global_Atmospheric_CO2_Budget/links/53cfb550cf2fd75bc59e69d.pdf)  
DOI: 10.1126/science.247.4949.1431

Tilastokeskus 2020a. [viitattu 27.11.2020] Saatavilla  
[https://www.stat.fi/tup/khkinv/khkaasut\\_suominir.html](https://www.stat.fi/tup/khkinv/khkaasut_suominir.html)



Tilastokeskus 2020b . Euroopan parlamentin ja Neuvoston n:o 280/2004/EY päätös. tehty 11.2.20004 [Viitattu 27.11.2020.

Saatavilla][https://www.stat.fi/static/media/uploads/tup/khkinv/eu\\_paatos\\_2004-280\\_paatos.pdf](https://www.stat.fi/static/media/uploads/tup/khkinv/eu_paatos_2004-280_paatos.pdf)

Tolonen, K. 1979. Peat as a renewable resource: long-term accumulation rates in northeuropean mires. In: Proceedings of the International Symposium on Classification of Peat and Peatlands Hyytiälä, Finland, pp. 282–296

Turunen, J. 2003 Past and present carbon accumulation in undisturbed boreal and subarctic mires. Suo 54 (1), pp. 15-28. [viitattu 25.9.2020] Saatavissa [https://www.researchgate.net/publication/247120261\\_Past\\_and\\_present\\_carbon\\_accumulation\\_in\\_undisturbed\\_boreal\\_and\\_subarctic\\_mires\\_A\\_review](https://www.researchgate.net/publication/247120261_Past_and_present_carbon_accumulation_in_undisturbed_boreal_and_subarctic_mires_A_review)

Turunen, J., Tomppo, E. , Tolonen, K., Reinikainen, A.2002. Estimating carbon accumulation rates of undrained mires in Finland -application to boreal and subarctic regions. The Holocene 12 (1).pp.69-80[viitattu 1.10.2020]. Saatavissa <https://journals.sagepub.com/doi/pdf/10.1191/0959683602h1522rp>

Turunen, J., Tahvanainen, T. Tolonen, K., Pitkänen, A. 2001. Carbon accumulation in West Siberian mires, Russia. Global Biogeochemical Cycles, 15 (2), pp. 285-296

Turunen, J., Valpola, S. 2020. The influence of anthropogenic land use on Finnish peatland area and carbon stores 1950-2015. Mires and Peat, 26, Article 27 pp 27. [Viitattu 3.12.2020] Saatavilla <http://mires-and-peat.net/pages/volumes/map26/map2626.php>

USGS 2018. Landsat Missions. Landsat 7. [viitattu 15.9.2020] Saatavilla [https://www.usgs.gov/core-science-systems/nli/landsat/landsat-7?qt-science\\_support\\_page\\_related\\_con=0#](https://www.usgs.gov/core-science-systems/nli/landsat/landsat-7?qt-science_support_page_related_con=0#)

Valta–Hulkkonen, K., Pellikka, P. Tanskanen, H. Ustinov A., Sandman, O. 2003. Digital false colour aerial photographs for discrimination of aquatic macrophyte species. *Aquatic Botany*, 75:71–88.

Van Den Eckhaut, M., Poesen, J., Verstraeten, G., Vanecker, V., Nyssen, J., Moyersons, J., Van Bleek, L.P.H., Vanderchove, L., 2007. Use of LIDAR-derived images for mapping old landslides under forest. *Earth Surf. Process. Landf.* 32, 754–769.

<https://doi.org/10.1002/esp.1417>

Verduzco, B., Fairhead, J.D., Green, C.M., 2004. New insights into magnetic derivatives for structural mapping. *Lead. Edge* 23, 116–119. <https://doi.org/10.1190/1.1651454>.

Virtanen, K., Hänninen, P., Kallinen R.L., Vartiainen, S., Herranen, T., Jokisaari, R. 2003 Suomen turvevarat. Tutkimusraportti 156, Geologian tutkimuskeskus Wissner, D., Marchenko, S., Talbot, J. Treat, C., Froking, S. 2011. Soil Temperature Response to 21st Century Global Warming. *Earth System Dynamics* 2, pp 121-138 [viitattu 25.10.2020] Saatavissa [www.earth-syst-dynam.net/2/121/2011/](http://www.earth-syst-dynam.net/2/121/2011/)

Wu, T.-F., Lin, C.-J. and Weng, R.C., 2004. Probability estimates for multi-class classification by pairwise coupling. *Journal of Machine Learning Research* 5, pp. 975-1005.

YU, Z., C. 2012. Northern Peatland carbon stocks and dynamics :a review. *Biogeosciences*, 9, pp,4071–4085. [viitattu 1.10.2020]. Saatavissa [www.biogeosciences.net/9/4071/2012/](http://www.biogeosciences.net/9/4071/2012/)  
doi:10.5194/bg-9-4071-2012

Ympäristöministeriö 2020. Kioton pöytäkirja. ].[viitattu 27.10.2020] Saatavissa:  
<https://ym.fi/kioton-poytakirja>

## 10. LIITTEET

### LIITE 1 Keidassuon luokituksen konfuusio -matriisi

Overall Accuracy = (5217/6205) 84.0774%  
Kappa Coefficient = 0.6721

	Ground Truth (Pixels)				
Class	mataspinta	tevali_mataspihmarkapinta	teallikko	testivali	markapin
Unclassified	0	0	0	0	0
mataspinta	312	111	26	0	0
vali_mataspin	6	537	9	189	92
markapinta	1	8	4135	36	127
allikko	0	0	14	35	0
vali_markapin	0	0	188	11	122
mataspinta_pu	0	0	6	0	0
Total	319	656	4378	271	341

Ground Truth (Pixels)		
Class	mataspinta_pu	Total
Unclassified	0	0
mataspinta	54	503
vali_mataspin	0	833
markapinta	16	4323
allikko	0	49
vali_markapin	94	415
mataspinta_pu	76	82
Total	240	6205

Ground Truth (Percent)					
Class	mataspinta	tevali_mataspihmarkapinta	teallikko_testivali	markapin	
Unclassified	0.00	0.00	0.00	0.00	0.00
mataspinta	97.81	16.92	0.59	0.00	0.00
vali_mataspin	1.88	81.86	0.21	69.74	26.98
markapinta	0.31	1.22	94.45	13.28	37.24
allikko	0.00	0.00	0.32	12.92	0.00
vali_markapin	0.00	0.00	4.29	4.06	35.78
mataspinta_pu	0.00	0.00	0.14	0.00	0.00
Total	100.00	100.00	100.00	100.00	100.00

Ground Truth (Percent)		
Class	mataspinta_pu	Total
Unclassified	0.00	0.00
mataspinta	22.50	8.11
vali_mataspin	0.00	13.42
markapinta	6.67	69.67
allikko	0.00	0.79
vali_markapin	39.17	6.69
mataspinta_pu	31.67	1.32
Total	100.00	100.00

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
mataspinta	37.97	2.19	191/503	7/319
vali_mataspin	35.53	18.14	296/833	119/656
markapinta	4.35	5.55	188/4323	243/4378
allikko	28.57	87.08	14/49	236/271
vali_markapin	70.60	64.22	293/415	219/341
mataspinta_pu	7.32	68.33	6/82	164/240

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
mataspinta	97.81	62.03	312/319	312/503
vali_mataspin	81.86	64.47	537/656	537/833
markapinta	94.45	95.65	4135/4378	4135/4323
allikko	12.92	71.43	35/271	35/49
vali_markapin	35.78	29.40	122/341	122/415
mataspinta_pu	31.67	92.68	76/240	76/82

## LIITE 2 Aapasuoennluokituksen konfuusio- matriisi

Overall Accuracy = (30264/39654) 76.3202%

Kappa Coefficient = 0.6500

Ground Truth (Pixels)					
Class	mataspinta_tevali	mataspin	markapinta_tevali	markapin	mataspinta_pu
Unclassified	0	0	0	0	0
mataspinta	13130	219	0	0	2004
vali_mataspin	3047	2294	528	455	916
markapinta	0	13	14123	349	65
vali_markapin	0	195	1468	0	0
mataspinta_pu	80	51	0	0	717
Total	16257	2772	16119	804	3702

Ground Truth (Pixels)	
Class	Total
Unclassified	0
mataspinta	15353
vali_mataspin	7240
markapinta	14550
vali_markapin	1663
mataspinta_pu	848
Total	39654

Ground Truth (Percent)					
Class	mataspinta_tevali	mataspin	markapinta_tevali	markapin	mataspinta_pu
Unclassified	0.00	0.00	0.00	0.00	0.00
mataspinta	80.77	7.90	0.00	0.00	54.13
vali_mataspin	18.74	82.76	3.28	56.59	24.74
markapinta	0.00	0.47	87.62	43.41	1.76
vali_markapin	0.00	7.03	9.11	0.00	0.00
mataspinta_pu	0.49	1.84	0.00	0.00	19.37
Total	100.00	100.00	100.00	100.00	100.00

Ground Truth (Percent)	
Class	Total
Unclassified	0.00
mataspinta	38.72
vali_mataspin	18.26
markapinta	36.69
vali_markapin	4.19
mataspinta_pu	2.14
Total	100.00

Class	Commission (Percent)	Omission (Percent)	Commission (Pixels)	Omission (Pixels)
mataspinta	14.48	19.23	2223/15353	3127/16257
vali_mataspin	68.31	17.24	4946/7240	478/2772
markapinta	2.93	12.38	427/14550	1996/16119
vali_markapin	100.00	100.00	1663/1663	804/804
mataspinta_pu	15.45	80.63	131/848	2985/3702

Class	Prod. Acc. (Percent)	User Acc. (Percent)	Prod. Acc. (Pixels)	User Acc. (Pixels)
mataspinta	80.77	85.52	13130/16257	13130/15353
vali_mataspin	82.76	31.69	2294/2772	2294/7240
markapinta	87.62	97.07	14123/16119	14123/14550
vali_markapin	0.00	0.00	0/804	0/1663
mataspinta_pu	19.37	84.55	717/3702	717/848

Liite 3 Mallikuva aapasuon testialueista

